

UNIVERSIDADE FEDERAL DE SÃO CARLOS

CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA

PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

**ESTRATÉGIAS PARA DELIMITAÇÃO DE REGIÕES
DE INTERESSE NA VISUALIZAÇÃO DE CONSULTAS
POR SIMILARIDADES**

CLAUDIO EDUARDO PAIVA

ORIENTADOR: PROF. DR. RENATO BUENO

São Carlos - SP
Novembro/2018

UNIVERSIDADE FEDERAL DE SÃO CARLOS

CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA

PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

**ESTRATÉGIAS PARA DELIMITAÇÃO DE REGIÕES
DE INTERESSE NA VISUALIZAÇÃO DE CONSULTAS
POR SIMILARIDADES**

CLAUDIO EDUARDO PAIVA

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de São Carlos, como parte dos requisitos para a obtenção do título de Mestre em Ciência da Computação, área de concentração: Engenharia de Software / Banco de Dados

Orientador: Prof. Dr. Renato Bueno

São Carlos - SP
Novembro/2018

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO
**ESTRATÉGIAS PARA DELIMITAÇÃO DE REGIÕES DE INTERESSE
NA VISUALIZAÇÃO DE CONSULTAS POR SIMILARIDADES**

CLAUDIO EDUARDO PAIVA

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de São Carlos, como parte dos requisitos para a obtenção do título de Mestre em Ciência da Computação, área de concentração: Engenharia de Software / Banco de Dados.

Membros da Banca:

Prof. Dr. Renato Bueno
(Orientador – DC-UFSCar)

Prof. Dr. Ricardo Rodrigues Ciferri
(DC-UFSCar)

Prof. Dr. Joaquim Cezar Felipe
(USP/RP)

São Carlos - SP
Novembro/2018



UNIVERSIDADE FEDERAL DE SÃO CARLOS

Centro de Ciências Exatas e de Tecnologia
Programa de Pós-Graduação em Ciência da Computação

Folha de Aprovação

Assinaturas dos membros da comissão examinadora que avaliou e aprovou a Defesa de Dissertação de Mestrado do candidato Claudio Eduardo Paiva, realizada em 01/11/2018:

Prof. Dr. Renato Bueno
UFSCar

Prof. Dr. Ricardo Rodrigues Ciferri
UFSCar

Prof. Dr. Joaquim Cezar Felipe
USP

Certifico que a defesa realizou-se com a participação à distância do(s) membro(s) Joaquim Cezar Felipe e, depois das arguições e deliberações realizadas, o(s) participante(s) à distância está(ao) de acordo com o conteúdo do parecer da banca examinadora redigido neste relatório de defesa.

Prof. Dr. Renato Bueno

À minha esposa Evelise e minha filha
Liliana, meus maiores motivos.

Em memória de meus pais Antônio e
Maria, meus maiores exemplos em tudo.

AGRADECIMENTO

Este trabalho representa a realização de um sonho de longa data. Chegar a este ponto significa muito para mim e quero agradecer a todos que estiveram comigo neste caminho.

Agradeço a Deus, por tudo.

À minha esposa Evelise que, com amor e sabedoria soube me incentivar nos momentos de desânimo. Lutou ao meu lado e entendeu minha ausência em vários momentos durante este projeto.

Ao meu orientador prof. Dr. Renato Bueno pela excelente maneira como conduziu este trabalho. Pelas palavras de incentivo, o conhecimento compartilhado e a compreensão dispensada a mim quando precisei.

Aos amigos que fiz no mestrado, especialmente Rafael pelo apoio e incentivo.

Aos professores e funcionários do Departamento de Computação.

A todos que não estão citados aqui, mas contribuíram para a realização deste trabalho.

RESUMO

O aumento do volume de dados que vem acontecendo nos últimos tempos tem gerado necessidade de novos métodos de armazenamento e recuperação de informações não só para os já conhecidos dados convencionais, mas também para dados complexos, como as imagens. Em um banco de dados de imagens, consultas baseadas em conteúdo podem ser realizadas por meio de comparações de características das imagens como cor, textura e forma para descobrir objetos semelhantes a uma dada imagem de busca. O fato de que as pessoas conseguem fazer análises visuais mais eficientemente do que de outras formas, torna a visualização de dados uma importante aliada na criação de conhecimento nas mais diversas áreas. Por isto, este trabalho tem o objetivo de estudar maneiras de visualizar os resultados de consultas por similaridade em dados complexos, limitando-se apenas à região em que a consulta está sendo realizada, mapeando os dados em espaços tridimensionais e permitindo que os usuários possam interagir com eles, alterando a visualização e sendo favorecidos pela percepção humana para melhorar a análise e o entendimento dos dados.

Palavras-chave: Consulta por similaridade. Dados complexos. Espaços métricos. Visualização. Mapeamento multidimensional.

ABSTRACT

The increase in data volume that has been occurring in recent time has generated the need for new methods of storing and retrieving information not only for the well known conventional data but also for the complex data such as images. In an image database, content-based searches can be done by comparing image characteristics such as color, texture, and shape to find objects similar to a particular search image. The fact, which people can do visual analysis more efficiently than in other ways, makes data visualization an important ally in creating knowledge in many different areas. Therefore, this study aims at analysing ways of visualizing the results of queries similarity in complex data, limiting itself only to the region that the query is being carried out, mapping the data in three-dimensional space and allowing users to interact with them, by changing the visualisation and being favored by the human perception to improve the analysis and the understanding of the data.

Keywords: Similarity query. Complex data. Metric spaces. Visualization. Multidimensional mapping.

LISTA DE FIGURAS

Figura 2.1 - Pontos calculados pelas métricas da família Minkowski (Adaptado de BÖHM; BERCHTOLD; KEIM, 2001).....	27
Figura 2.2 - Consulta por abrangência.....	29
Figura 2.3 - Consulta aos 5 vizinhos mais próximos.....	29
Figura 3.1 - Classificação das técnicas de visualização de informações (Adaptado de KEIM, 2005).....	35
Figura 4.1 – Exemplo de variação do ângulo de rotação de 0 a 45 graus de objeto fotografado do conjunto ALOI.....	49
Figura 4.2 – Região de interesse composta por 10 elementos.....	51
Figura 4.3 – Região de interesse composta por 5000 elementos.....	51
Figura 4.4 – Região de interesse composta por 5000 elementos - Detalhe.....	52
Figura 4.5 – Região de interesse composta por 5000 elementos - Detalhe.....	52
Figura 4.6 – Aumento do erro inserido no processo de mapeamento para diferentes quantidades de elementos.....	53
Figura 4.7 – Visualização de consulta k-NN simples.....	54
Figura 4.8 – Imagens retornadas em consulta k-NN (k=7). Em (a) a imagem usada como centro de busca. Em (b) o conjunto resposta da consulta.....	56
Figura 4.9 – Visualização de consulta com alteração da região de interesse com percentual de aumento.....	57
Figura 4.10 – Imagens visualizadas em consulta com alteração da região de interesse com percentual de aumento de k . Em (a) a imagem usada como centro de busca. Em (b) o conjunto de imagens visualizadas.....	58
Figura 4.11 – Visualização de consulta com alteração da região de interesse com percentual de aumento do raio do k-NN simples.....	60
Figura 4.12 – Imagens visualizadas em consulta com alteração da região de interesse com percentual de aumento do raio do k-NN simples.....	61
Figura 4.13 – Visualização de consulta com alteração da região de interesse com percentual de aumento do raio do k-NN simples.....	62
Figura 4.14 – Imagens visualizadas em consulta com alteração da região de interesse com percentual de aumento do raio do k-NN simples.....	63
Figura 4.15 – Consulta 5-NN em uma região densa.....	65

Figura 4.16 – Raio estimado pela dimensão fractal para 5-NN em uma região densa.	66
Figura 4.17 – Consulta 5-NN em uma região esparsa.	67
Figura 4.18 – Raio estimado pela dimensão fractal para 5-NN em uma região esparsa.	68
Figura 4.19 – Elementos adicionados à região de interesse com uso da dimensão fractal.	69
Figura 4.20 – Imagens visualizadas em consulta com alteração da região de interesse pela dimensão fractal. Em (a) a imagem usada como centro de busca. Em (b) o conjunto de imagens visualizadas.	70
Figura 4.21 – Elementos adicionados à região de interesse com uso da dimensão fractal.	71
Figura 4.22 – Imagens visualizadas em consulta com alteração da região de interesse com percentual de aumento pela dimensão fractal. Em (a) a imagem usada como centro de busca e em (b) o conjunto resultado.	72
Figura 4.23 – Imagens retornadas em consulta k-NN (k=12). Em (a) a imagem usada como centro de busca. Em (b) o conjunto resposta da consulta.	73
Figura 4.24 – Exclusão de elementos da região de interesse com uso da dimensão fractal. Em destaque, os elementos eliminados do resultado.	74
Figura 4.25 – Visualização de 5-NN com acréscimo de 100% sobre o número de elementos retornados: região densa.	75
Figura 4.26 – Visualização de 5-NN com acréscimo de 100% sobre o número de elementos retornados usando dimensão fractal: região densa.	76
Figura 4.27 – Visualização de 5-NN com acréscimo de 100% sobre o número de elementos retornados: região esparsa.	77
Figura 4.28 – Visualização de 5-NN com acréscimo de 100% sobre o número de elementos retornados usando dimensão fractal: região esparsa.	78
Figura 4.29 – Visualização de consulta com acréscimo de % k para cálculo do raio.	79
Figura 4.30 – Imagens visualizadas em consulta com acréscimo de % k para cálculo do raio. Em (a) a imagem usada como centro de busca. Em (b) o conjunto visualizado.....	80
Figura 4.31 – Alteração da região de interesse com aumento em percentual do raio estimado.....	81
Figura 4.32 – Imagens visualizadas em consulta com alteração do raio estimado. ...	81
Figura 5.1 – Exemplo de evolução de dados ao longo do tempo (Adaptado de Sousa e Bueno, 2014).....	84

Figura 5.2 – Análise visual dos 4 vizinhos mais próximos em uma consulta (Adaptado de Sousa e Bueno, 2014).....	85
Figura 5.3 – Visualização de consulta com estimativa de trajetória métrico-temporal.	87
Figura 5.4 – Imagens recuperadas em consulta com estimativa de trajetória métrico-temporal. Em (a) as imagens usadas para estimar. Em (b) as imagens do conjunto resposta da consulta.....	88
Figura 5.5 – Visualização de consulta com estimativa de trajetória métrico-temporal com alteração da região de interesse por acréscimo do k	89
Figura 5.6 – Imagens visualizadas em consulta com estimativa de trajetória métrico-temporal. Em (a) as imagens usadas para estimar. Em (b) as imagens da região de interesse.....	90
Figura 5.7 – Consulta com estimativa de trajetória métrico-temporal com alteração da região de interesse pela dimensão fractal.....	91
Figura 5.8 – Imagens visualizadas em consulta com estimativa de trajetória métrico-temporal. Em (a) as imagens usadas para estimar. Em (b) as imagens da região de interesse.....	92
Figura 5.9 – Consulta com estimativa de trajetória métrico-temporal.....	93
Figura 5.10 – Imagens recuperadas em consulta com estimativa de trajetória métrico-temporal. Em (a) as imagens usadas para estimar. Em (b) as imagens da região de interesse.....	94
Figura 5.11 – Consulta com estimativa de trajetória métrico-temporal com alteração da região de interesse pela dimensão fractal com aumento em percentual do raio estimado.....	95
Figura 5.12 – Imagens recuperadas em consulta com estimativa de trajetória métrico-temporal. Em (a) as imagens usadas para estimar. Em (b) as imagens da região de interesse.....	96

LISTA DE TABELAS

Tabela 4.1 – Matriz de distâncias (7-NN).....	55
---	----

LISTA DE ABREVIATURAS E SIGLAS

- CBIR** – *Content-Based Image Retrieval*
- CBR** – *Content-Based Retrieval*
- GPL** – *General Public License*
- HSV** – *Hue, Saturation, Value*
- IDE** – *Interface Development Enviroment*
- InfoVis** – *Information Visualization*
- K-NNq** – *k-Nearest Neighbors Query*
- LAMP** – *Local Affine Multidimensional Projection*
- LoCH** – *Local Convex Hull*
- LSP** – *Least Square Projection*
- MAM** – *Metric Access Methods*
- MD** – *Mineração de dados*
- MSD** – *Multidimensional Scaling*
- PCA** – *Principal Component Analysis*
- PHOG** – *Pyramidal Histogram of Oriented Gradients*
- PLP** – *Piecewise Laplacian Projection*
- RGB** – *Red, Green, Blue*
- RQ** – *Range Query*
- SAM** – *Spatial Access Methods*
- SGBD** – *Sistemas Gerenciadores de Bando de Dados*
- SQL** – *Structure Query Language*

SUMÁRIO

CAPÍTULO 1 - INTRODUÇÃO.....	15
1.1 Contexto.....	15
1.2 Motivação e objetivos.....	17
1.3 Metodologia de desenvolvimento do trabalho.....	18
1.4 Organização do trabalho.....	19
CAPÍTULO 2 - RECUPERAÇÃO DE DADOS BASEADA EM CONTEÚDO.....	20
2.1 Considerações iniciais.....	20
2.2 Extração de características das imagens.....	22
2.3 Medidas de similaridade.....	26
2.4 Tipos de consultas por similaridade.....	28
2.4.1 Consulta por abrangência.....	28
2.4.2 Consulta aos vizinhos mais próximos.....	29
2.5 Métodos de acesso métricos.....	30
2.6 Considerações finais.....	31
CAPÍTULO 3 - MINERAÇÃO VISUAL DE DADOS.....	32
3.1 Considerações iniciais.....	32
3.2 Mineração visual de dados.....	33
3.3 Técnicas de exploração visual de dados.....	35
3.4 Técnicas de interação visual.....	38
3.5 Técnicas para projeção de dados multidimensionais.....	40
3.6 Ferramentas para visualização.....	44
3.7 Considerações finais.....	45
CAPÍTULO 4 - VISUALIZAÇÃO DE CONSULTAS POR SIMILARIDADE: DELIMITAÇÃO DA REGIÃO DE INTERESSE.....	47
4.1 Considerações iniciais.....	47
4.2 Materiais e métodos.....	48
4.3 Consulta k-NN simples.....	54
4.3.1 Consulta k-NN: expansão com % k de elementos.....	56

4.3.2 Consulta k-NN: expansão por % do raio do k-NN simples	59
4.4 Uso da dimensão fractal para delimitar a região de interesse.....	64
4.4.1 Estimativa do raio de consulta: regiões densas	68
4.4.2 Estimativa do raio de consulta: regiões esparsas	73
4.4.3 Expansão do raio em consultas com dimensão fractal	74
4.4.4 Estimativa do raio da consulta com acréscimo % de k para cálculo do raio.....	78
4.4.5 Estimando o raio da consulta com acréscimo de % do raio estimado.....	80
4.5 Considerações finais	82
CAPÍTULO 5 - VISUALIZAÇÃO DE ESTIMATIVAS DE TRAJETÓRIAS	
MÉTRICOS-TEMPORAIS	83
5.1 Considerações iniciais.....	83
5.2 Estimativa de trajetória métrico-temporal em consulta k-NN.....	86
5.3 Expansão da região de interesse com % de k elementos	89
5.4 Delimitação da região de interesse pela dimensão fractal	90
5.5 Alteração da região de interesse com acréscimo de % do raio estimado	93
5.6 Considerações finais	96
CAPÍTULO 6 - CONSIDERAÇÕES FINAIS.....	97
6.1 Principais contribuições.....	99
6.2 Trabalhos futuros	99
REFERÊNCIAS.....	101

Capítulo 1

INTRODUÇÃO

1.1 Contexto

As incontáveis fontes de dados que as pessoas confrontam todos os dias para realizar suas tarefas têm percebido um significativo aumento no volume e complexidade dos seus dados, o que demanda a criação de técnicas e estratégias específicas para sua manipulação.

Aplicações que tratavam números ou cadeias de caracteres, hoje englobam outros tipos de dados complexos ou não convencionais, como imagens, vídeos e sons, que são gerados pelo crescente uso de sensores para captar dados, novas tecnologias para realização de exames médicos, maior acesso pelas pessoas a dispositivos de captura de imagem e vídeo, entre outras tecnologias.

Neste sentido, extrair dados de uma base de dados para análise, é tão importante quanto o seu armazenamento e permite às pessoas gerar novos conhecimentos em suas áreas de atuação, seja na indústria, comércio, medicina, educação ou outra área qualquer. Bancos de dados que trabalham com dados convencionais, atuando sobre números, caracteres e datas, possibilitam a aplicação de filtros por meio de comparações relacionais, a fim de selecionar os dados desejados para análise.

Em se tratando de dados não convencionais, operações de consultas são tarefas igualmente importantes, porém, nestas consultas a utilização de operadores relacionais não são usuais.

Dentre o conjunto de tipos de dados não convencionais, este trabalho conduzirá seus estudos com imagens, que podem ser analisadas por meio de suas características como cores, formas e texturas.

Tais características são extraídas por algoritmos desenvolvidos para este propósito, geralmente armazenadas em vetores e representadas em espaços métricos, onde somente elementos e as suas distâncias são conhecidos, não possuindo representações geométricas ou com coordenadas dimensionais.

Desta maneira, a similaridade entre imagens é considerada segundo a aplicação de uma função de distância, permitindo que recuperações de dados similares sejam feitas por comparações das características.

Como nos bancos de dados convencionais, espera-se que uma consulta a dados complexos baseada em conteúdo seja realizada com sucesso e de forma eficiente, o que torna necessário o uso de estruturas de otimização para consultas especialmente desenvolvidas para este domínio de dados, os métodos de acessos métricos.

Um sistema de recuperação de dados baseado em conteúdo, com extratores de características de imagens, organização e armazenamento em vetores de características, métodos de acessos definidos e funções de distância capazes de indicar qual a similaridade existente entre as imagens, é complementado com técnicas de visualização de dados, o que permite aos usuários fazerem interpretações utilizando-se da percepção visual, conseguindo assim, melhorar seus entendimentos e análises.

A visualização de dados oferece vantagens para a interpretação humana de semelhança entre imagens por permitir que seja considerada a riqueza dos detalhes envolvidos ao fazer as análises. Tal situação não é possível ser reproduzida com exatidão pelos algoritmos que processam imagens, devido ao fato destes não serem capazes de ponderar a semântica nas suas análises, o que pode gerar uma diferença entre o que é processado e o que é tido como ótimo pelos usuários.

A visualização de consultas de imagens baseadas em conteúdo é o foco principal deste trabalho.

1.2 Motivação e objetivos

Embora seja possível fazer a representação de dados não convencionais por meio de números que expressam suas características primitivas, para os usuários, fazer a interpretação de imagens por meio de um conjunto de números não é uma tarefa trivial. Tal fato não acontece da mesma maneira quando a representação dos dados se dá de forma gráfica pois, interpretar dados de forma visual permite que os usuários explorem e analisem os dados mais facilmente, selecionando em um menor espaço de tempo informações importantes que precisam para tomar suas decisões.

Um sistema de visualização de dados permite que o usuário tenha melhor compreensão do conjunto analisado, favorecendo a geração de conhecimentos, pois baseia-se na percepção visual humana.

Assim, o objetivo deste trabalho é usar técnicas de visualização para explorar apenas uma região específica do conjunto de dados, composta pelos elementos retornados em uma consulta juntamente com os elementos próximos desta área pesquisada. Pretende-se usar projeção multidimensional em um espaço 3D para visualizar os resultados das consultas.

Diversos trabalhos apresentam formas de visualização de grandes conjuntos de dados, porém, limitar a quantidade de dados a serem analisados permite conseguir uma distribuição no espaço mapeado mais próximos do espaço real.

Um dos fatores motivadores para a execução deste trabalho é o estudo dos dados métricos-temporais realizado por (BUENO, 2009) e (SOUSA; BUENO, 2014). Este tipo de dado é importante em diversas áreas onde é preciso tratar a informação temporal como por exemplo, em aplicações médicas em que é preciso acompanhar a evolução de pacientes por meio de imagens de seus exames médicos. Em seus estudos (BUENO, 2009) e (SOUSA; BUENO, 2014) fizeram uma análise da evolução destes dados complexos com o passar do tempo a partir de elementos tomados como elementos de referência e demonstraram como uma estimativa para os dados pode ser feita por meio do estudo de suas trajetórias ao longo do tempo.

Um protótipo foi criado e permitiu que apenas os elementos retornados por uma consulta juntamente com os demais elementos desta região fossem projetados e visualizados em um ambiente 3D. Este protótipo foi testado com um conjunto de dados

variados que permitiram, inclusive, realizar a análise dos dados métricos-temporais citados anteriormente.

1.3 Metodologia de desenvolvimento do trabalho

Neste trabalho não se pretende visualizar todo o conjunto de dados complexos, mas apenas os resultados de consultas por similaridade e a região próxima a estes resultados. Para isto foram estudadas e propostas formas de determinar a região de proximidade (além dos elementos retornados pela consulta), criando uma região de interesse que pôde ser visualizada e interpretada.

Neste trabalho tal região de interesse pode ser definida diretamente pelo usuário, em razão de uma porcentagem sobre o número de elementos retornados pela consulta ou feito de maneira automática por meio de estudos sobre a dimensão fractal do conjunto de dados, que também pode ser alterada por percentual informado. Experimentos foram realizados visando entender e validar os resultados apresentados na visualização de acordo com cada parâmetro escolhido.

Assim, como o conjunto de dados a ser visualizado inclinou-se a ser pequeno, pois foi limitado à região da consulta, a utilização de métodos computacionais mais custosos para projeção multidimensional em 3 dimensões não foi proibitiva.

Buscou-se uma maneira de aperfeiçoar a representação gráfica dos dados retornados pelas consultas que permitisse entender melhor a sua distribuição, como forma de auxiliar o usuário na interpretação de quais elementos estão próximos da região da consulta e quais não estão. Esse tipo de análise é especialmente útil na análise das consultas baseadas nas estimativas das trajetórias métrico-temporais de (BUENO, 2009). Nestas consultas os mesmos recursos foram utilizados para visualizar todas as regiões envolvidas, ou seja, as regiões próximas aos elementos de referências.

O estudo da aplicabilidade de técnicas de interação visual como a filtragem interativa, zoom interativo e distorção interativa, permitiram criar formas para o usuário trabalhar diretamente na visualização, alterando-a por meio de zoom ou rotações aos dados representados.

1.4 Organização do trabalho

Este trabalho está dividido em seis capítulos, detalhados a seguir:

O Capítulo 1 apresenta o trabalho de forma resumida, contextualizando-o, descrevendo sua motivação, os objetivos do seu desenvolvimento e a metodologia utilizada.

O Capítulo 2 traz os conceitos básicos sobre recuperação de dados baseada em conteúdo, definindo dados não convencionais e como são trabalhados por meio de suas características, apresenta os principais tipos de consultas por similaridade, descreve como se dá a manipulação de dados complexos em espaços métricos e a indexação por métodos de acessos.

No Capítulo 3 o conceito de mineração visual de dados é apresentado, onde algumas técnicas de exploração visual de dados e de interação visual são introduzidas, é definida a visualização de informação e também são apresentadas técnicas de projeção de dados multidimensionais.

Os Capítulos 4 e 5 trazem o resultado do trabalho desenvolvido, onde são apresentados em detalhes alguns dos experimentos realizados, bem como uma análise descritiva dos resultados alcançados.

No capítulo 6 são apresentadas as considerações finais e propostas de trabalhos futuros.

Capítulo 2

RECUPERAÇÃO DE DADOS BASEADA EM CONTEÚDO

O conceito de dados não convencionais e como podem ser representados por suas características é fundamental para o entendimento de um sistema de recuperação de dados baseada em conteúdo. Este capítulo define o que são dados complexos e como eles podem ser trabalhados para uso em consultas por similaridade.

2.1 Considerações iniciais

À medida em que a tecnologia avança, a busca por mais conhecimento impulsiona a necessidade de análise de dados com maior riqueza de detalhes nas mais diversas áreas em que a computação está presente (BÖHM; BERCHTOLD; KEIM, 2001). Entretanto, considerar mais detalhes de dados, muitas vezes, implica em um aumento substancial no volume de informações, requerendo novos métodos para armazenamento e acesso a estes dados (SINGHAI; SHANDILYA, 2010).

Além dos conhecidos dados convencionais, tais como números e cadeias de caracteres, é possível fazer uso de dados não convencionais para tarefas de análises de dados e aquisição de novos conhecimentos. Dados não convencionais podem ser quaisquer dados oriundos de fontes não triviais, como sons, vídeos, imagens, entre outros (HECZKO et al., 2004).

Para que tais dados não convencionais possam ser utilizados de forma eficiente, além de técnicas de armazenamento também é importante empregar técnicas capazes de realizar operações de manipulação destes dados (TORRES;

FALCÃO, 2006). Em um banco de dados de imagens, por exemplo, podem ser utilizadas palavras-chave para catalogar os objetos de maneira textual, fornecendo uma descrição para cada imagem. Isto possibilita realizar pesquisas utilizando-se os métodos tradicionais com linguagem de consulta (por exemplo, comandos SQL) (SHIVAMURTHY; MANJUNATHA; PRADEEP KUMAR, 2015)

Embora o processo de descrever as imagens atribuindo-lhes alguns termos seja relativamente simples, ele pode não ser tão eficiente, já que depende da percepção humana para definir termos descritivos e as pessoas podem ter opiniões diferentes com relação ao que uma imagem representa. Além disto, descrever cada objeto de um grande conjunto de dados torna-se praticamente inviável do ponto de vista prático, sendo uma tarefa que demanda muito tempo para ser executada (TORRES; FALCÃO, 2006).

As operações de busca também podem ser feitas por meio de comparações entre características extraídas dos dados e que representam seu conteúdo. Estas consultas são chamadas de Consultas Baseadas em Conteúdo (*Content-Based Retrieval* – CBR) ou, quando imagens são consideradas, Consultas de Imagem Baseadas em Conteúdo (*Content-Based Image Retrieval* – CBIR) (BARROSO; BUENO, 2013).

Atualmente, grandes quantidades de arquivos de imagens digitais são geradas pelas mais variadas fontes e a todo instante. Sistemas CBIR envolvem qualquer tecnologia empregada na organização destes arquivos, observando seu conteúdo visual, desde uma função que trate a similaridade entre elas, a um poderoso mecanismo para notação destas imagens (DATTA et al., 2008).

Pessoas comuns deixaram de ser meros consumidores de fotografias, passando a produzi-las em larga escala, capturando e compartilhando imagens do mundo ao seu redor (DATTA et al., 2008).

No campo da astronomia e sensoriamento remoto, os dados de imagens gerados por estações terrestres, para processamento, análise e armazenamento constituem um vasto banco de dados (PETRAKIS; FALOUTSOS, 1997).

A medicina também tem produzido um alto volume de imagens digitais (por exemplo, Tomografia Computadorizada, Ressonância Magnética, etc.) e vem utilizando tais dados para diagnósticos e terapias diversas (KUMAR; SENTHILMURUGAN, 2013) (PETRAKIS; FALOUTSOS, 1997).

Nos bancos de dados convencionais, onde é possível trabalhar com dados primitivos como os números e cadeias de caracteres, os dados apresentam relação de ordem total, o que possibilita a utilização de operadores relacionais na recuperação dos dados. Porém, em bancos de dados que consideram dados complexos ou não convencionais, tal relação de ordem não pode ser feita ou oferece pouca utilidade, sendo necessária uma maneira diferente de descobrir elementos similares entre si (TRAINA JR. et al., 2002).

A seção 2.2 deste capítulo descreve porque é importante extrair e armazenar características de imagens. A seção 2.3 apresenta o conceito de medidas de similaridade, espaços métricos e funções de distância. Na seção 2.4 são apresentados alguns tipos de consulta por similaridade, como a consulta por abrangência, descrita na subseção 2.4.1 e a consulta aos vizinhos mais próximos, explicada na subseção 2.4.2 e, finalmente, na seção 2.5 é discutida a importância do uso de métodos de acessos para a indexação de dados complexos.

2.2 Extração de características das imagens

Em sistemas CBIR, algoritmos são usados para processar as imagens da base de dados com o propósito de extrair propriedades ou características visuais suficientemente capazes de representar seus conteúdos. Este processamento é uma das fases essenciais deste tipo de sistema, uma vez que são estas características que permitem que as imagens sejam indexadas e recuperadas automaticamente (KUMAR; SENTHILMURUGAN, 2013).

Depois de processadas e extraídas, as características são comumente armazenadas em estruturas de vetores e são utilizadas para descrever as imagens, de forma a proporcionar uma alternativa ao método textual com uso de palavras-chaves (BÖHM; BERCHTOLD; KEIM, 2001).

Assim, é possível aplicar uma métrica (como a distância euclidiana) para avaliar a semelhança entre duas imagens, e conseqüentemente entre uma imagem qualquer e as imagens da base de dados. O conjunto formado pelo extrator de características e uma função de distância para comparar duas imagens quaisquer é conhecido como descritor (TORRES; FALCÃO, 2006).

As principais características que podem ser extraídas das imagens são relacionadas a cor, a textura e a forma. Elas são conhecidas como características primitivas (ASLANDOGAN; YU, 1999), sendo que a cor é o elemento mais utilizado na recuperação de imagens (SHEREENA; DAVID, 2014).

Extratores de características baseados em cores podem utilizar diferentes modelos, ou espaços de cores, para fazer a representação de uma imagem. O modelo RGB (*red, green, blue*), embora seja muito tradicional, não é o que melhor representa a percepção humana de cores e por isto não é o mais utilizado para indexação e consultas por imagens. Já o modelo HSV (*hue, saturation, value*), por conseguir representar mais precisamente o modelo de cores que os humanos são capazes de perceber, é usado com mais frequência (MÜLLER et al., 2004).

Alguns exemplos de extratores de características de imagens frequentemente usados são os coeficientes gerados pelas transformadas de Fourier, que são baseadas em formas (ZHANG; LU, 2001) e o histograma de cor (SWAIN; BALLARD, 1991).

Em Huang et al. (1999) uma nova característica de imagem chamada de correlograma cor foi definida e usada para a indexação e comparação de imagens. Ela considera a correlação espacial de cores e, quando calculada de forma eficiente, é eficaz e de baixo custo para recuperação de imagens baseada em conteúdo. Segundo os autores, o correlograma cor é robusto em tolerar grandes mudanças na aparência e forma da imagem, causada por mudanças como a posição de visualização ou o zoom da câmera. Os resultados do estudo demonstram que esta funcionalidade é mais eficaz do que o histograma de cor, com armazenamento adicional insignificante e baixo custo de processamento.

A característica textura também é utilizada na busca por imagens. Ela pode ser definida como sendo um padrão visual em que a estrutura das superfícies é formada pela repetição de um determinado número de elementos visíveis, arranjados de maneira uniforme em diferentes posições na imagem (ASLANDOGAN; YU, 1999).

A característica forma pode ser definida como sendo uma silhueta da imagem (LONCARIC, 1998). Ela é um elemento visual importante e pode ser considerada uma característica primitiva de grande relevância para a recuperação de imagens pelo fato de que a visão humana pode identificar um objeto pela sua forma melhor do que por outra característica. Ainda que uma imagem seja apresentada como algo mais

simplificado, não necessitando ser apresentada como uma imagem colorida ou texturizada, tal imagem será facilmente identificada (BIEDERMAN, 1987).

Porém, embora a forma tenha grande facilidade de ser identificada pela visão humana, implementar sistemas CBIR baseados em formas é uma tarefa difícil, pois representar uma imagem real em 3D em um plano de imagem 2D faz com que uma dimensão da imagem seja perdida, gerando uma representação parcial do objeto original (ZHANG; LU, 2004).

Os métodos de extração de características de forma podem ser classificados em duas categorias: métodos baseados em contorno e métodos baseados em região. Tal classificação baseia-se na maneira como as características serão realmente extraídas, se somente a partir da borda ou se serão extraídos da região como um todo, considerando também os pontos do seu interior (ZHANG; LU, 2004).

Em Kunttu (2006) foram usadas as técnicas de Fourier para apresentação de duas novas abordagens baseadas em contorno.

Um estudo comparando as técnicas de descritores de Fourier e *wavelets* foi feito em Yadav et al. (2009), demonstrando a classificação de objetos com base em seus contornos de formas veiculares (automóveis, aviões, helicópteros, tanques, etc).

Berbar (2014) fez uso de transformadas de *wavelets* para tratar as características das imagens em um estudo para a classificação de gênero de imagens de faces humanas.

Ajeesh (2013) apresentou uma visão geral das técnicas de extração de características existentes, ressaltando tanto técnicas que exploram uma única característica primitiva, quanto técnicas que combinam diferentes características da imagem para ampliar a eficiência da recuperação. Foram abordadas técnicas como o histograma de cor, filtros de Gabor e momentos de Zernike.

Em Shereena (2014) algumas técnicas de extração de características, incluindo momentos de cor, histograma de cores, correlograma cor e filtros de Gabor foram comparadas, demonstrando o aumento da eficiência de recuperação de imagens quando as características de cor e textura são combinadas. Foram tratadas as medidas de similaridade com as quais as imagens são recuperadas e a indexação eficaz de imagens com base nas características visuais representadas.

Outra comparação entre vários descritores de forma, amplamente adotados para CBIR pode ser vista em Zhang e Lu (2001b), onde foram analisados os pontos fortes e também as limitações de métodos como os descritores de Fourier, descritores

de curvatura em espaço de escala, descritores de momento de Zernike e descritores de grade.

Apesar da possibilidade de se empregar várias técnicas para a tarefa de extração de características, em sistemas CBIR, muitas vezes os resultados obtidos automaticamente divergem da interpretação humana. Considerando esta questão, Eakins (2002) identifica três níveis diferentes de consulta por imagem:

- Nível 1: indica a recuperação feita com base nas características primitivas extraídas diretamente da imagem como cor, textura, forma ou localização espacial de elementos nesta imagem, não necessitando de conhecimentos externos à ela. Um exemplo deste tipo de consulta pode ser: *“encontrar imagens semelhantes a uma imagem dada como referência”*.
- Nível 2: são recuperações realizadas com base em algum atributo derivado ou característica lógica, envolvendo um certo grau de inferência sobre o conteúdo da imagem. Por exemplo: *“encontrar imagens de pessoas”*.
- Nível 3: compreendem as recuperações feitas considerando algum atributo abstrato, que exige um nível considerável de raciocínio sobre o significado da imagem. Um exemplo deste tipo de consulta: *“encontrar imagens de pessoas felizes”*.

Os algoritmos que processam as características primitivas possuem uma interpretação limitada se comparada à interpretação humana de semelhança entre imagens, pois a interpretação humana é rica em detalhes e é capaz de considerar a semântica ao fazer comparações. Este fato pode causar uma diferença entre o resultado considerado pelo usuário e o resultado dado de maneira automática pelos algoritmos. Esta diferença é conhecida como *gap* semântico (SMEULDERS et al., 2000) e existe porque, enquanto o processamento automático só é capaz de interpretar as imagens com base em características de baixo nível, os humanos são capazes de detectar características tanto de baixo nível, quanto características semânticas (WANG; MOHAMAD; ISMAIL, 2010).

Outra diferença que pode existir em sistemas CBIR é a diferença sensorial (*sensory gap*), que pode ser entendida como sendo a perda entre a estrutura real e a representação de uma imagem por suas características (KUMAR; SENTHILMURUGAN, 2013).

2.3 Medidas de similaridade

O grau de similaridade entre dois objetos de um banco de dados é calculado a partir da aplicação de uma medida de (dis)similaridade aos seus vetores de características (AREVALILLO-HERRÁEZ; DOMINGO; FERRI, 2008).

Esta função é também chamada de função de distância e retorna um valor sempre maior ou igual a zero. Quando o valor retornado é muito próximo do zero, significa que objetos muito similares foram comparados. Um resultado igual a zero indica objetos iguais e para resultados maiores que zero, quanto maior for este valor, menor será o grau de similaridade entre os objetos (BRAUNMULLER et al., 2000). Segundo afirma o autor, espera-se que o resultado da aplicação de uma função de distância aos vetores de características de duas imagens represente matematicamente a percepção humana de similaridade entre estes objetos, da melhor maneira possível.

Conjuntos de dados em que uma função de distância métrica é usada para calcular a semelhança entre seus pares de elementos, podem ser representados em espaços métricos (BRIN, 1995). Um espaço métrico pode ser definido como sendo um par (O, d) , onde O indica o domínio de um conjunto de objetos ($O = (O_1, O_2, \dots, O_n)$), e d é a distância métrica que possui as seguintes propriedades (TORRES; FALCÃO, 2006):

- Simetria: $(d(O_1, O_2) = d(O_2, O_1))$
- Positividade: $(0 < d(O_1, O_2) < \infty, O_1 \neq O_2 \text{ e } d(O_1, O_1) = 0)$
- Desigualdade triangular: $(d(O_1, O_3) \leq d(O_1, O_2) + d(O_2, O_3))$

As seguintes funções de distância métricas são amplamente usadas em buscas por similaridades: distância euclidiana, Chebyshev e Manhattan (AJEESH; INDU, 2013).

Elas fazem parte das funções da família Minkowski (L_p) (WILSON; MARTINEZ, 1997). De acordo com os autores, considerando-se dois vetores de características x e y em um espaço de dimensão m , podem ser representadas matematicamente como:

$$d(x, y) = \sqrt[p]{\sum_{i=1}^m |x_i - y_i|^p} \quad (2.1)$$

- Quando $p=1$ tem-se a chamada distância Manhattan ou *City Block* (L_1):

$$L_1(x, y) = \sum_{i=1}^m |x_i - y_i| \quad (2.2)$$

- Quando $p=2$ tem-se o caso mais conhecido das métricas da família Minkowski, a conhecida distância Euclidiana (L_2), definida por:

$$L_2(x, y) = \sqrt{\sum_{i=1}^m |x_i - y_i|^2} \quad (2.3)$$

- Quando p vai ao infinito, tem-se a distância Chebyshev (L_∞), definida por:

$$L_\infty(x, y) = \max_{i=1}^m (|x_i - y_i|) \quad (2.4)$$

A figura 2.1 mostra um conjunto de pontos calculados pelas funções da família Minkowski para um espaço bidimensional.




Figura 2.1 - Pontos calculados pelas métricas da família Minkowski (Adaptado de BÖHM; BERCHTOLD; KEIM, 2001).

O contorno em forma de losango é o resultado da métrica Manhattan ou *City Block*, os pontos que formam o contorno do círculo foram calculados pela métrica Euclidiana e os pontos que delimitam o quadrado mais externo foram obtidos a partir da métrica Chebyshev.

2.4 Tipos de consultas por similaridade

Consultas em domínios de dados complexos são feitas a partir de um objeto empregado como centro de busca e considerando-se critérios de similaridade capazes de definir o quão semelhantes os objetos são (RODRIGUES JR. et al., 2010).

Diferentemente de consultas quando considerando dados convencionais, consultas a dados complexos não são feitas com comparação de igualdade ou baseadas em comparações relacionais ($>$, $<$, \geq , \leq , $<>$), uma vez que estes dados não apresentam relação de ordem total e muitas vezes não interessa saber se uma imagem é igual a outra, mas sim, saber quais imagens são mais semelhantes ou mais distintas da imagem dada (TRAINA JR. et al., 2002). Segundo os autores, as consultas por similaridade mais utilizadas em domínios métricos, quando se considera o uso de imagens, são as consultas por abrangência e consulta aos vizinhos mais próximos, detalhadas a seguir.

2.4.1 Consulta por abrangência

Uma consulta de similaridade por abrangência (*Similarity Range Query – RQ*) considera um elemento central de consulta e retorna os elementos do conjunto de dados que estão a uma distância máxima deste elemento de referência (TORRES; FALCÃO, 2006).

Em outras palavras, busca por abrangência pode ser definida como um conjunto de objetos $S=\{s_1, s_2, \dots, s_n\}$ do domínio D , uma função de distância d , um objeto central de consulta sq como referência e uma distância r calculada por uma função de distância (RODRIGUES JR.; TRAINA; TRAINA JR., 2005).

A figura 2.2 mostra um exemplo de consulta por abrangência utilizando a função de distância Euclidiana.




Figura 2.2 - Consulta por abrangência.

Os objetos que estão dentro do círculo pontilhado representam o subconjunto dos dados que foram recuperados.

2.4.2 Consulta aos vizinhos mais próximos

Em um espaço métrico, encontrar os vizinhos mais próximos significa encontrar os elementos do conjunto de dados que têm as menores distâncias ao elemento de consulta (BRIN, 1995). Segundo o autor, este tipo de consulta é conhecido como consulta aos k -vizinhos mais próximos (*k-Nearest Neighbors query* - k -NNq) e retorna os k elementos mais similares ao elemento chave.

A figura 2.3 mostra um exemplo de consulta aos k -vizinhos mais próximos usando uma função de distância Euclidiana. Todos os objetos que estão ligados por uma linha ao elemento chave formam o conjunto dos dados recuperados.




Figura 2.3 - Consulta aos 5 vizinhos mais próximos.

Neste exemplo está demonstrada uma consulta aos 5 vizinhos mais próximos, ou seja, é o resultado da uma consulta quando $k=5$.

2.5 Métodos de acesso métricos

Sempre que uma operação é realizada em uma base dados, espera-se que ela seja realizada de maneira eficiente, o que faz com que a indexação seja considerada uma ferramenta indispensável para os sistemas gerenciadores de banco de dados, já que os índices garantem o melhor rendimento nas operações, podendo, inclusive, acelerar a execução de consultas para a recuperação de dados (CONGYUN YANG; KING-IP LIN, 2001).

Assim como em banco de dados tradicionais, os índices (ou métodos de acesso) existem no domínio dos dados complexos, contudo, uma vez que este tipo de dados não possui relação de ordem total, métodos de acesso específicos são necessários para garantir que as operações sejam realizadas de forma satisfatória (HJALTASON; SAMET, 2003b).

O fato de que os vetores de características usados para representar as imagens tendem a ter alta dimensionalidade faz com estes vetores não sejam adequados para serem gerenciados pelas estruturas de indexação tradicionais, gerando necessidades de estruturas de índices específicas para cada tipo de dado complexo (SHEREENA; DAVID, 2014).

Este conjunto de métodos de acesso pode ser classificado como métodos de acesso espaciais e métodos de acesso métricos, sendo estes últimos, os mais adequados para lidar com consultas por similaridade.

Métodos de acesso espaciais (*Spatial Access Methods* - SAM) são usados para indexar dados em um espaço multidimensional, onde o tipo de estrutura considera o posicionamento de cada objeto a ser indexado (CHÁVEZ et al., 2001).

Métodos de acesso métricos (*Metric Access Methods* – MAM) são usados para indexar e recuperar dados complexos e precisam conhecer apenas quais são os objetos a serem indexados e qual é a função de distância métrica definida para o domínio dos objetos (CHINO et al., 2005).

Um MAM para dados em espaços métricos chamado *M-Tree* foi proposto em (CIACCIA; PATELLA; ZEZULA, 1997). Os autores mostram que este método utiliza uma estrutura de árvore equilibrada, capaz de lidar com dados dinâmicos, isto é, inserções e exclusões feitas na base de dados não exigem reorganizações dispendiosas na estrutura de índices, evitando a degradação do desempenho.

O MAM chamado *Slim-tree* também utiliza uma árvore equilibrada e dinâmica para organizar seus índices e gerencia os dados em páginas de tamanho fixo no disco, sendo que cada página corresponde a um nó da árvore e os objetos são armazenados nas suas folhas (TRAINA JR. et al., 2000). De acordo com os autores, este método oferece uma maneira simples de quantificar o grau de sobreposição entre os nós em uma árvore, além de ser a primeira estrutura métrica explicitamente projetada para reduzir o grau de sobreposição.

O aumento da capacidade e a redução de custos da memória principal também motivaram a criação de MAMs e um exemplo é o método *Onion-Tree*. Baseado em memória dinâmica, este método requer apenas uma pequena parte da memória principal para execução e está baseado na divisão hierárquica do espaço métrico em subespaços disjuntos. Os autores compararam o método proposto com alguns outros métodos baseados em memória, demonstrando a vantagem do *Onion-Tree* em relação aos outros no que diz respeito ao tempo decorrido necessário para processamento de consultas e redução no número de cálculos de distância para gerenciamento da estrutura de índices (CARÉLO et al., 2011).

2.6 Considerações finais

Dados complexos estão sendo gerados pelas mais diversas áreas em que a computação está presente e, como possuem mais detalhes que dados convencionais, exigem métodos específicos para gerenciamento e armazenamento. Neste domínio de dados, operações de busca são feitas comparando-se características extraídas dos dados, sendo que tais consultas formam os sistemas conhecidos como CBIR, se um banco de dados de imagens está sendo considerado.

Neste capítulo foram apresentados alguns conceitos básicos para o entendimento de sistemas CBIR, como o papel dos extratores de características, tipos mais comuns de consultas por similaridade, funções de medidas e os benefícios da utilização de métodos de acessos métricos para tornar as buscas mais eficientes. O próximo capítulo apresenta os conceitos e a importância da mineração visual de dados, demonstrando como ela pode agilizar e favorecer o entendimento dos dados por parte dos usuários.

Capítulo 3

MINERAÇÃO VISUAL DE DADOS

Este capítulo apresenta o conceito de mineração visual de dados, discute algumas técnicas de exploração e interação visuais disponíveis, enfatizando suas importâncias no processo de interpretação de dados pelos usuários.

3.1 Considerações iniciais

Ao trabalhar com grandes bases de dados os usuários podem encontrar dificuldades em selecionar as informações realmente relevantes para a sua necessidade. Uma maneira de amenizar esta dificuldade é fazer uso de técnicas de visualização da informação (FREITAS et al., 2001).

Segundo Gershon e Eick (1997), visualização é o processo de transformar os dados, apresentando-os de uma forma gráfica, permitindo que as pessoas tenham um rápido reconhecimento visual de padrões. Para os autores, ela permite que os usuários selecionem as informações que precisam e tomem decisões em um tempo relativamente curto.

Para (KEIM, 1997), os objetivos da visualização da informação podem ser divididos em três categorias:

- **Análise exploratória:** enquanto não existirem hipóteses sobre os dados, esta é a atividade de buscar por padrões e tendências. Ao final, a visualização dos dados fornece hipóteses sobre os mesmos.
- **Análise confirmativa:** a visualização dos dados tem a finalidade de confirmar ou rejeitar uma hipótese já conhecida.

- Apresentação: depois de descobertos os fatos, uma ferramenta de visualização deve ser capaz de mostrar os dados de forma eficiente.

Na seção 3.2 deste capítulo é apresentado o conceito de mineração visual de dados, que combina técnicas de mineração com técnicas de visualização de dados para melhorar o entendimento de informações por parte dos usuários. Na seção 3.3 são descritas algumas técnicas de exploração visual e uma classificação é feita. Técnicas de interação visual são descritas na seção 3.4. Na seção 3.5 são descritas algumas técnicas para projeção de dados multidimensionais. Por fim, algumas ferramentas para análise visual de dados são expostas na seção 3.6.

3.2 Mineração visual de dados

O avanço contínuo das tecnologias de *hardware* permite que os sistemas de computador atuais armazenem grandes quantidades de dados (KEIM; SIPS; ANKERST, 2005), porém, segundo os autores, se este volume de dados gerados não puder ser explorado e analisado adequadamente, eles se tornam inúteis e as bases de dados onde estão guardados tornam-se desnecessárias. Esta análise não é uma tarefa fácil e a cada dia novas pesquisas são feitas a fim de encontrar técnicas que possibilitem obter informações importantes dos dados coletados.

Apresentar os dados de uma forma visual, permitindo a interação do usuário para que, de acordo com sua percepção, obtenha *insights* sobre os dados, tire conclusões e interaja diretamente com os dados é a ideia básica da mineração visual de dados (KEIM, 2002).

Esta combinação de técnicas de visualização de informação, algoritmos de mineração de dados e a possibilidade de interação humana, busca melhorar a eficiência dos processos de exploração de informações (ANKERST, 2001).

De acordo com Fayyad (1998), o processo capaz de explorar e extrair informações úteis de uma base de dados é frequentemente conhecido pelo termo mineração de dados (*Data Mining* - MD) e faz parte de um processo global de descoberta de conhecimento, composto por outras etapas que envolvem também a

preparação das bases de dados, a busca de padrões, a avaliação dos conhecimentos e o refinamento dos resultados obtidos.

A mineração visual de dados normalmente segue um processo que permite ao usuário ter uma visão geral dos dados, a aplicação de filtros e a apresentação de detalhes específicos de algum item ou conjunto de itens, conhecido como *Visual Information Seeking Mantra* (SHNEIDERMAN, 1996).

Neste processo, o primeiro passo deve disponibilizar uma visão geral das informações disponíveis a fim de permitir que o usuário identifique alguns padrões de seu interesse e concentre-se neles. Logo após, a filtragem de informações específicas (ou descarte de informações indesejáveis) é obtida pela aplicação de zoom e filtragem aos dados escolhidos e, depois que os itens de interesse foram localizados, passa-se a selecioná-los, com o propósito de obter detalhes adicionais (KEIM, 2002).

Shneiderman (1996) propôs um tipo de taxonomia de tarefas, dividindo o processo de visualização em sete tarefas distintas:

- Visão geral: Obter uma visão geral de todos os dados.
- Zoom: aplicar zoom sobre itens de interesse.
- Filtro: filtrar itens que não são interessantes.
- Detalhes sobre demanda: selecionar um item, ou grupo de itens, e obter detalhes quando necessário.
- Relacionamentos: entender as relações entre os itens.
- Histórico de ações: manter um histórico para possibilitar desfazer uma ação, criar repetições e/ou conseguir um refinamento progressivo.
- Extração de informações: permitir a extração de subconjuntos de itens e dos parâmetros de consulta.

Diferentes técnicas de mineração de dados aliadas às técnicas de visualização e interação foram estudadas em (OLIVEIRA; LEVKOWITZ, 2003) para análise visual de grandes conjuntos de dados.

Um exemplo sobre as contribuições da mineração visual de dados pode ser vista em (SHNEIDERMAN; PLAISANT; HESSE, 2013), destacando a importância do uso desta tecnologia para a saúde.

3.3 Técnicas de exploração visual de dados

De acordo com Keim et al. (2005), existem muitas técnicas de exploração visual de informação. Os autores sugerem que estas técnicas podem ser classificadas de acordo com três critérios definidos: os dados a serem visualizados, a técnica de visualização em si e a técnica de interação e distorção empregadas. A figura 3.1 mostra esta classificação proposta.

Os tipos de dados usados para esta classificação incluem os dados representados em uma única dimensão, dados bidimensionais, multidimensionais, textos e hipertextos, dados hierárquicos e gráficos, além de algoritmos e *softwares* (SHNEIDERMAN, 1996). Em seu artigo, o autor cita alguns exemplos destes tipos de dados.




Figura 3.1 - Classificação das técnicas de visualização de informações (Adaptado de KEIM, 2005).

Sobre as técnicas de visualização, Keim (2002) apresentou uma classificação para elas, dividindo-as em projeções 2D/3D convencionais, técnicas baseadas em projeções geométricas, baseadas em ícones, orientadas a pixels, técnicas hierárquicas e técnica híbrida quando algumas técnicas são combinadas. Segundo o autor, esta classificação se resume em:

- **Projeções 2D/3D convencionais:** foram classificadas nesta categoria as técnicas simples e bastante utilizadas como as plotagens X-Y (X-Y-Z), os gráficos de barras, os gráficos de linhas e os mapas.

- **Projeções geométricas:** para englobar as técnicas de visualização que visam mapear dados de um espaço multidimensional em uma apresentação bidimensional.
- **Baseadas em ícones:** nesta categoria estão as técnicas que fazem uso de símbolos ou ícones de aparência familiar aos seres humanos para representar os dados, mapeando os valores dos atributos de um conjunto de dados multidimensionais em características desses ícones, que podem incluir pequenos rostos, varas, ícones de cor e/ou formas geométricas.
- **Orientadas a pixels:** foram incluídas nesta categoria as técnicas de visualização que possuem como ideia básica o mapeamento de cada valor dos atributos multidimensionais em um pixel, agrupando os pixels pertencentes a cada dimensão em áreas adjacentes para serem apresentados em janelas de visualização separadas. Esta técnica divide a tela de visualização em várias subjanelas onde compara os elementos em relação a cada atributo específico. Para conjuntos de dados com m dimensões, a tela é também dividida em m subjanelas, uma para cada uma das dimensões. Como esta técnica utiliza apenas um pixel colorido para cada valor de atributo representado, ela permite a visualização de conjuntos de dados muito grandes, mantendo uma visão global de grandes quantidades de dados ao mesmo tempo em que preserva a percepção de pequenas regiões de interesse (ANKERST, 2001).
- **Técnicas hierárquicas:** nas técnicas desta categoria, os dados são particionados e apresentados de forma hierárquica. Esta técnica subdivide um espaço k -dimensional em subespaços que são apresentados hierarquicamente, usando o conceito de incorporação de um sistema de coordenadas dentro de um outro sistema de coordenadas mais amplo. Por exemplo, dois atributos formam o sistema de coordenadas exterior, outros dois atributos são incorporados ao sistema de coordenadas exterior, e assim por diante.

A seguir são apresentadas resumidamente algumas técnicas de visualização. Outras diversas técnicas podem ser vistas em (GRINSTEIN; TRUTSCHL; CVEK, 2001).

A técnica de coordenadas paralelas é um exemplo de técnica de projeção geométrica cujo funcionamento é baseado no mapeamento de um espaço K-dimensional para uma exibição em duas dimensões usando eixos equidistantes K e que são paralelos a um dos eixos de exibição (INSELBERG; DIMSDALE, 1987).

Em (RAO; CARD, 1994) a técnica *Table Lens* foi proposta para visualização de grandes volumes de dados, permitindo ao usuário isolar e investigar características e padrões de seu interesse.

Kandogan (2000) propôs uma técnica de projeção geométrica chamada *Star Coordinates*, com o intuito de apoiar os usuários em estágios iniciais de suas atividades de pensamento visual. Esta técnica foi utilizada em (KHALID et al., 2014) para descobrir grupos de associações e relações entre os dados de pacientes com câncer de mama.

A técnica *Scatter Plots* (WARD, 1994), também classificada como técnica de projeção geométrica, é bastante usada para projetar dados de altas dimensões em espaços bidimensionais. É uma das técnicas mais antigas de visualização de dados. Sua aplicação gera pares de projeções paralelas sendo que cada um desses pares representa a relação das informações contidas entre duas dimensões.

Tree-Map (SHNEIDERMAN, 1992) é uma técnica para visualização de dados hierárquicos e que utiliza de forma eficiente todo o espaço de representação disponível. Esta técnica subdivide recursivamente o espaço de visualização em regiões retangulares a fim de representar cada item da hierarquia como um retângulo preenchido. Os tamanhos dos retângulos são proporcionais a algum atributo escolhido pelo usuário e as suas posições representam a localização dos itens na hierarquia. A utilização eficiente de todo o espaço permite que hierarquias muito grandes sejam exibidas por completo e facilita a apresentação de informação semântica.

Uma técnica de visualização de dados hierárquicos chamada *Sunburst*, que apresenta os dados de forma radial, foi proposta em (ZHANG; STASKO, 2000). Os autores também fizeram uma comparação com a técnica *Tree-Map* e destacam que a nova técnica faz melhor uso do espaço de exibição para representar simultaneamente todos os nós de uma hierarquia, o que é importante para comparações baseadas em estrutura, como identificar o ancestral comum mais próximo. A técnica *Sunburst* foi usada recentemente em um estudo da medicina em (GLUECK et al., 2016).

3.4 Técnicas de interação visual

Além das técnicas de visualização, a exploração de dados eficaz requer ainda o uso de algumas técnicas de interação e de distorção. As técnicas de interação permitem que o usuário interaja diretamente com a visualização, criando alterações dinâmicas de acordo com seus objetivos, e as técnicas de distorção garantem meios para focalizar determinadas regiões, preservando uma visão geral do conjunto de dados (HINNEBURG; KEIM; WAWRYNIUK, 1999).

De acordo com (GERSHON; EICK; CARD, 1998), bons sistemas de visualização precisam implementar o que se sabe sobre a compreensão e interação humana com as informações, observando fatores sobre a percepção humana e isto é um grande desafio. Segundo os autores, criar interfaces de usuário flexíveis, ferramentas de navegação e métodos de pesquisa apropriados para cada um dos tipos existentes de usuários é uma tarefa difícil, pois envolve entender melhor como os seres humanos interagem com a informação, como a percebe visualmente e como a mente humana funciona na busca de informações, conhecidas ou não.

Keim (2005) também destaca a importância do uso de técnicas de interação combinadas com técnicas de visualização para obter uma exploração visual de dados mais eficaz. Algumas técnicas de interação foram destacadas pelo autor:

- **Projeção dinâmica:** é uma operação de navegação cuja ideia básica é redefinir dinamicamente as projeções dos dados ao longo do tempo, permitindo que o usuário explore um grande conjunto de dados multidimensionais. Estas redefinições podem tanto ser feitas de forma automatizada pelo sistema, quanto ser o resultado de uma interação do usuário, selecionando subconjuntos de dados para visualização.
- **Filtragem interativa:** oferece a possibilidade de selecionar e tratar segmentos de dados, concentrando os esforços utilizados apenas nos subconjuntos de interesse. Esta filtragem pode ser feita através de uma seleção direta do subconjunto desejado depois que os dados foram visualizados (*browsing*) ou por uma especificação de propriedades do subconjunto desejado, neste caso, não necessitando que os dados sejam previamente exibidos (*querying*).

- **Zoom interativo:** é uma técnica de interação utilizada por muitas aplicações e que oferece uma forma de visualizar diferentes partes do conjunto de dados. Ao passo em que uma visão geral permite que o usuário detecte padrões, correlações e valores discrepantes no conjunto de dados, ao mudar a representação, aplicando níveis mais elevados de zoom, esta técnica permite explorar uma região de interesse, disponibilizando mais informações a respeito destes objetos, já que passará a representar os dados de interesse de maneira mais detalhada.
- **Distorção interativa:** é uma técnica que apoia o processo de exploração de dados, porém, preservando uma visão geral do conjunto de dados. Ela está fundamentada em mostrar porções dos dados com um alto nível de detalhes, enquanto outros são mostrados com um menor nível de detalhes, ficando a critério do usuário a escolha por visualizar os detalhes de maior interesse. Algumas técnicas de distorção populares são as distorções hiperbólicas e as distorções esféricas.
- **Linking & Brushing:** cada uma das técnicas de visualização de dados possui suas forças e fraquezas, com isto, *Linking & Brushing* tem o objetivo de combinar diferentes técnicas para analisar um mesmo conjunto de dados a fim de superar as deficiências que possam existir de forma individual. Desta maneira, mais informações são fornecidas do que se considerando as visualizações de forma independente e fica garantido que as mudanças feitas em uma visualização, automaticamente se refletem nas demais visualizações.

Outras técnicas de interação também foram descritas em (ELMQVIST; FEKETE, 2010): *Zoom & Pan, Drill-down and Roll-up, Local Aggregation Control, Flipping, Coupled Zooming e Drilling*.

A participação humana no processo de exploração de dados combina flexibilidade, criatividade e conhecimento geral do usuário com a enorme capacidade de armazenamento e o poder computacional dos computadores (KEIM; SIPS; ANKERST, 2005). Segundo os autores, quando um conjunto de dados é disponibilizado de forma interativa e gráfica, muitas vezes favorece o surgimento de conhecimentos, estimulando a formação e validação de melhores hipóteses para

resolução de problemas, permitindo que o usuário aprofunde seu conhecimento no domínio explorado.

3.5 Técnicas para projeção de dados multidimensionais

Fazer a avaliação da similaridade entre pares de objetos a partir de sua informação de distância é uma tarefa relativamente fácil, mas não é tão óbvio quanto avaliá-los quando são representados por pontos em um espaço. Por esta razão, mapear objetos complexos em espaços de baixas dimensões torna-se uma ideia muito promissora e pode favorecer a interpretação dos dados e de suas relações pelos usuários (FALOUTSOS; LIN, 1995).

Uma técnica para projeção de dados multidimensionais pode ser definida como o mapeamento das instâncias de um conjunto de dados, originalmente em espaço m -dimensional, para um espaço visual de 1, 2 ou 3 dimensões, preservando as posições relativas dos elementos e refletindo algum tipo de relacionamento entre estas instâncias de dados, tais como vizinhança ou similaridade fornecida por uma função de distância definida sobre o espaço m -dimensional (PAULOVICH et al., 2010).

Imagens podem ser representadas como pontos em espaços de alta dimensão (pois extrair as características primitivas de imagens, pode gerar vetores de características com muitos atributos), o que dificulta a indexação destes espaços e configura o que é conhecido como maldição da alta dimensionalidade (*curse of dimensionality*) (BERCHTOLD; BOHM; KRIEGEL, 1998).

Desta maneira, esquemas de indexação tradicionais que executam razoavelmente bem para um pequeno número de dimensões, passam a ter um mau desempenho, necessitando que técnicas de redução de dimensionalidade sejam aplicadas para tratar este problema (TORRES; FALCÃO, 2006).

Reduzir o número de dimensões é uma forma comum de lidar com a questão da dimensionalidade e permite aplicar estratégias já conhecidas para dados em baixas dimensões (PAULOVICH et al., 2008). Segundo os autores, quando os dados são projetados em espaços com até 3 dimensões, é possível criar uma representação gráfica que permite tirar vantagem da capacidade visual humana para reconhecer similaridade entre os dados.

Um algoritmo bem conhecido para projeção multidimensional é o *Multidimensional Scaling* (MDS), que permite realizar mapeamentos de espaços métricos ou em altas dimensões para espaços de menor dimensão (geralmente euclidianos), preservando as características do conjunto de dados originais por meio de cálculos de distância entre pares de objetos (KRUSKAL, 1964). Este algoritmo possui complexidade $O(n^2)$ (quadrático), o que o torna impraticável para grandes conjuntos de dados (FALOUTSOS; LIN, 1995).

Em seu artigo, (KRUSKAL, 1964) apresentou um critério para quantificar a qualidade do mapeamento realizado chamado *Stress* (tensão). Segundo os autores, valor de *stress* menor significa um melhor ajuste na representação dos dados e o valor zero significa ajuste "perfeito".

Uma técnica conhecida como *Fastmap* (FALOUTSOS; LIN, 1995) foi proposta para redução de dimensionalidade. De acordo com os autores, esta técnica tem o objetivo de mapear objetos de um espaço em alta dimensão para novos pontos em um espaço p -dimensional de tal forma que as similaridades sejam preservadas entre os objetos tanto quanto possível, com complexidade $O(n)$ para execução.

Um algoritmo chamado *SparseMap* foi proposto em (HRISTESCU; FARACH-COLTON, 1999) originalmente com a finalidade de mapear sequências de proteínas em um espaço euclidiano de baixa dimensão e com o intuito de preservar, da melhor maneira possível, as distâncias entre os elementos do conjunto de dados. De acordo com os autores, fazer avaliações de distância entre sequências de proteínas tem custo computacional alto, e este foi o principal motivo para a criação de um método que fosse capaz de reduzir o número de avaliações de distâncias entre elementos e que mantivesse as relações biológicas entre as proteínas representadas.

Para mapear os dados, o algoritmo *SparseMap* trabalha analisando subconjuntos do conjunto original de dados, executando projeções aleatórias. Em seu estudo, os autores fizeram comparações de famílias de proteínas utilizando *SparseMap* e *FastMap* e relataram que o *SparseMap* é um método eficiente e preciso para mapeamento de um banco de dados de proteínas em um espaço de baixa dimensão (HJALTASON; SAMET, 2003a).

Um algoritmo popular para a redução de dimensionalidade conhecido como Análise dos componentes principais (*Principal Component Analysis* - PCA), ou decomposição dos valores singulares fez parte do estudo apresentado em (VARGHESE, 2012).

Também conhecida como expansão de *Karhunen-Loève*, PCA é uma técnica clássica para redução de dimensionalidade, amplamente utilizada nas áreas de reconhecimento de padrões e visão computacional e está baseada na transformação do conjunto inicial por meio da produção de um conjunto de combinações lineares chamadas componentes principais (YANG et al., 2004). Os autores afirmam que, em essência, a PCA procura reduzir a dimensão dos dados encontrando algumas combinações lineares ortogonais dos atributos originais que possuem a maior variância, descartando as de menor. Assim, a combinação linear com maior variância será o primeiro componente principal, seguido da próxima combinação linear com maior variância sendo o segundo componente e assim sucessivamente. Nesse estudo, os autores desenvolverem uma nova técnica de análise de componente principal bidimensional (2DPCA) para a representação de imagens.

Uma outra técnica de projeção multidimensional chamada *Least Square Projection* (LSP) foi proposta em (PAULOVICH et al., 2008). Segundo os autores, esta técnica usa uma estratégia de projeção que tenta preservar as relações de vizinhança entre os objetos. Diferentemente de outras técnicas que buscam manter as relações de distância entre os objetos, ela busca garantir que objetos vizinhos do espaço multidimensional sejam projetados mantendo-se uma mesma vizinhança.

Dois processos principais são usados para realizar tal projeção: considerando-se R^m um conjunto de objetos em um espaço multidimensional e R^d o espaço de menor dimensão projetado, inicialmente é feita a escolha de um subconjunto de objetos em R^m , chamados de pontos de controle, que são projetados pelo método MDS tendo suas relações de distância preservadas; em seguida, fazendo uso das relações de vizinhança de R^m e das coordenadas cartesianas dos pontos de controle de R^d , um sistema linear pode ser construído, cujas soluções são as coordenadas cartesianas dos demais pontos em R^d .

Embora a técnica LSP apresente bons resultados no que diz respeito a preservação da vizinhança entre os objetos, o fato de envolver a solução de um sistema linear, a torna impraticável para grandes conjuntos de dados (PAULOVICH et al., 2011). Em seu novo estudo, o autor propõe uma técnica chamada *Piecewise Laplacian Projection* (PLP) capaz de solucionar este problema resolvendo vários pequenos sistemas lineares em vez de apenas um único sistema grande, isto é possível particionando-se o conjunto de dados em *clusters*. Segundo o autor, PLP é mais rápida do que LSP, porém, resulta em uma preservação de vizinhança pior.

Recentemente, (FADEL et al., 2015) classificaram as técnicas de projeção em dois grupos diferentes: as técnicas globais, que buscam manter no espaço projetado as relações de distância considerando todos os pares de objetos, e as técnicas locais, que por outro lado, têm como objetivo preservar as relações de distâncias considerando somente pequenas regiões no espaço multidimensional. Em seu trabalho, os autores apresentam uma nova técnica de projeção local denominada *Local Convex Hull* (LoCH), especialmente concebida para lidar com espaços esparsos de alta dimensionalidade, cuja ideia principal é preservar, tanto quanto possível, as relações de distância local entre objetos individuais enquanto mantém uma preservação global entre grupos de objetos.

De acordo com os autores, três etapas podem descrever esta técnica de maneira resumida: depois que o conjunto de dados foi dividido em *clusters*, calcula-se os k-vizinhos mais próximos para cada objeto considerando os agrupamentos gerados por cada *cluster*, então são selecionadas e projetadas amostras representativas de objetos em um plano, a fim de manter as relações de distância entre grupos de objetos semelhantes e finalmente é feita uma interpolação de todos os demais objetos, colocando cada um deles o mais próximos possível dos seus vizinhos mais próximos.

Outra técnica baseada em mapeamentos locais conhecida como *Local Affine Multidimensional Projection* (LAMP) foi proposta por (JOIA et al., 2011), onde, inicialmente, subconjuntos de dados são selecionados como pontos de controle e projetados em espaços de baixa dimensão (semelhantemente à técnica PLP), servindo como orientação para construir uma família de mapeamentos ortogonais, um para cada objeto a ser projetado. Segundo os autores, a capacidade de lidar com um número bastante reduzido de pontos de controle torna a LAMP adequada para aplicações interativas, permitindo que o usuário manipule os pontos de controle no espaço visual para melhor organizá-los e obter melhores análises.

O problema de projetar dados multidimensionais em dimensões mais baixas tem sido amplamente estudado e muitas técnicas já foram propostas devido às suas aplicações potenciais para a análise de dados de diversos tipos (PAULOVICH et al., 2008). Outras técnicas para projeção de dados multidimensionais podem ser vistas em (FODOR, 2002), (VARGHESE, 2012) e (SORZANO; VARGAS; MONTANO, 2014).

De acordo com (FALOUTSOS; LIN, 1995) existem duas situações pelas quais as técnicas de projeção de dados multidimensional podem ser analisadas: o problema geral, também conhecido como problemas das distâncias e o problema das características. A primeira situação trata os casos onde são conhecidos apenas os objetos e as informações das distâncias entre eles e no segundo caso estão as situações em que as características dos objetos foram extraídas e formam um conjunto com muitos atributos (tal fato é conhecido como maldição de dimensionalidade), sendo necessário diminuir o número de dimensões para representar os objetos. Em ambos os casos a projeção se preocupa em encontrar um espaço dimensional que represente os objetos, de modo a manter as distâncias entre eles da melhor forma possível.

As técnicas para projeção de dados multidimensional são uma importante ferramenta para a análise visual de dados de alta dimensionalidade. Este trabalho buscou abordagens baseadas no problema das distâncias entre os objetos.

3.6 Ferramentas para visualização

A análise visual de dados permite, por exemplo, observar a ocorrência de aglomerações, estudar o posicionamento de cada objeto em relação aos outros dentro do conjunto resposta e encontrar elementos distantes que possam ser considerados interessantes ou descartá-los do objetivo da pesquisa, a fim de ajudar o usuário a confirmar hipóteses ou formular novas ideias sobre os dados. Assim, o usuário é capaz de entender visualmente quais são os resultados mais relevantes e quais são os menos relevantes retornados pelo sistema de consulta.

Pensando nisto, diversas ferramentas têm sido desenvolvidas ao longo do tempo para auxiliar as análises de dados, permitindo ganho na interpretação graças à capacidade humana garantida pela percepção visual.

Uma ferramenta que permite fazer análise visual de dados chamada FastMapDB foi proposta em (TRAINA; TRAINA JR.; BOTELHO, 2001). Ela possibilita a extração de todos os dados de uma determinada relação armazenados em sistemas de bases de dados relacionais para que possam ser exibidos de forma gráfica e

interpretados visualmente, independentemente do tipo de dados de cada atributo da relação.

Na ferramenta FastMapDB, o usuário visualiza a distribuição dos objetos estudados em um espaço 3D sendo capaz, entre outras coisas, de interagir com a visualização ou preparar os dados para operações de *data mining* (BARIONI et al., 2002).

Outra ferramenta que implementa visualização de dados foi apresentada em (RODRIGUES JR.; ROMANI; CIFERRI, 2009). Chamada de *Metric Space Platform* (MetricSPlat), de acordo com os autores, com o objetivo de reduzir o ônus para se criar um sistema CBIR e agilizar o processo de análise, a plataforma oferece diversas funcionalidades visuais para melhorar a compreensão dos dados e permite a interação do usuário.

Esta ferramenta implementa um conjunto de várias técnicas para inspeção visual de todo o conjunto de dados sob análise e viabiliza a análise de resultados de consultas por similaridade aos vizinhos mais próximos ou por abrangência. São usadas técnicas de redução de dimensionalidade sobre todo o conjunto de dados e é permitido ao usuário examinar as visualizações e selecionar novos centros de buscas para consultar (RODRIGUES JR. et al., 2010).

Recentemente, um trabalho apresentou o Método k-NDN Visual-Interactive (ViK) (DIAS et al., 2017). Os autores expõem uma abordagem para visualizar e interagir em sistemas CBIR combinada com técnicas de mineração visual de dados (VDM), pensando em minimizar o problema do *gap* semântico de acordo com o conhecimento prévio do usuário. Para os autores, quando o usuário passa a assumir um papel ativo no processo de recuperação de imagens baseado em conteúdo, o seu *feedback* e conhecimento permitem obter melhorias no processo de descoberta de padrões e semelhanças entre as imagens, orientando e aumentando a qualidade dos resultados.

3.7 Considerações finais

Para os usuários, a tarefa de identificar informações importantes em um grande conjunto de dados pode ser facilitada se estes dados são apresentados de forma

gráfica. Desta forma, combinar técnicas de visualização de informação com mineração de dados e ainda ter a possibilidade de interagir com os dados, faz com que a exploração de informações seja executada de maneira mais eficiente.

Neste capítulo esta combinação de técnicas foi analisada sob a perspectiva da mineração visual de dados, mostrando também como a percepção humana tem papel importante na análise de informações. Foram apresentadas algumas técnicas de visualização e como estas podem ser classificadas e, finalizando o capítulo, técnicas de projeção de dados multidimensionais foram discutidas e suas importâncias para o processo de recuperação de imagens por conteúdo foram tratadas. O próximo capítulo apresenta o resultado do trabalho desenvolvido neste projeto de mestrado.

Capítulo 4

VISUALIZAÇÃO DE CONSULTAS POR SIMILARIDADE: DELIMITAÇÃO DA REGIÃO DE INTERESSE

Neste capítulo são apresentados experimentos realizados com o propósito de analisar visualmente os dados de uma região de interesse. Serão explicados o protótipo criado para consulta e visualização de resultados, detalhes da base de dados escolhida para os testes e a análise dos resultados.

4.1 Considerações iniciais

Como foi exposto no capítulo 3, dados representados graficamente favorecem a interpretação e análise pelos usuários mais do que outra forma de representação, graças à capacidade de percepção visual humana.

Este trabalho apresenta uma maneira de visualizar os dados recuperados em consultas por similaridade ao mapear para um ambiente 3D apenas um subconjunto de dados a serem visualizados, tal que os elementos de interesse considerados nas consultas sejam somente aqueles pertencentes à região da consulta em si. Não é, portanto, necessário manipular grandes quantidades de dados do conjunto completo.

Limitar o conjunto de dados a ser visualizado à apenas uma região de interesse permite obter uma melhor representação dos dados no espaço mapeado, já que o erro inserido pelo processo de projeção tende a ser menor à medida que o conjunto de dados a ser mapeado diminui.

A seção 4.2 apresenta os materiais e métodos utilizados para o desenvolvimento deste projeto. A seção 4.3 explora alguns cenários de consultas ao conjunto de dados escolhido para análise, mostrando como a região da consulta pode ser modificada por meio de parâmetros que atuam diretamente sobre o valor de k das consultas k -NN. O uso da dimensão fractal para delimitar a região de interesse está apresentado na seção 4.4. Diferentes formas de definição da região de interesse das consultas foram implementadas e estão apresentadas ao longo do capítulo.

4.2 Materiais e métodos

Para a condução deste trabalho de pesquisa em nível de mestrado, foi implementado um protótipo que permitiu extrair as características das imagens e realizar consultas por similaridade delimitando uma região de interesse sobre o conjunto de dados. Em seguida foi possível visualizar e interagir com os resultados recuperados.

Este protótipo foi desenvolvido em linguagem Java e implementado na IDE (*Interface Development Environment*) NetBeans¹ em sua versão 8.2. Ele possibilita, entre outras atividades, escolher critérios para definição da região de interesse de um conjunto de imagens para a visualização das respostas das consultas por similaridade. Tais critérios estão descritos ao longo deste capítulo.

Os processos de extração das características e indexação das imagens foram implementados com os recursos disponíveis na biblioteca de código livre chamada LIRE (abreviação de *Lucene Image Retrieval*), atualmente mantida no Github².

LIRE é uma biblioteca Java para recuperação de informações visuais em arquivos de imagens que oferece suporte para trabalhar com extratores de características globais e locais. Segundo os autores, ela provê abordagens simples e eficientes para a recuperação de imagens baseada em conteúdo (LUX et al., 2016). Lançada em fevereiro de 2006 sob licença GPL (*General Public License*), LIRE extrai as características das imagens e as armazena em um índice que é usado para futuras

¹ https://netbeans.org/index_pt_BR.html

² <https://github.com/dermotte/lire>

recuperações de informação (YANG; KAMATA, 2009). Trabalhos com uso desta biblioteca podem ser vistos em (CARDOSO, 2017), (HAUFF; THOMEE; TREVISIOL, 2013), (DEMNER-FUSHMAN et al., 2012), (ZHANG et al., 2010) e (WESTMAN; LUSTILA; OITTINEN, 2008).

Para a realização dos experimentos foi utilizada a subdivisão *Object Viewpoint* do conjunto de imagens ALOI (*Amsterdam Library of Object Images*) (GEUSEBROEK; BURGHOUTS; SMEULDERS, 2005). O conjunto ALOI é um repositório com 110.250 imagens de 1.000 objetos fotografados em diversas variações de ângulos de visão, ângulos de iluminação e cores de iluminação. Para a variação *Object Viewpoint* os objetos foram fotografados em 72 ângulos diferentes com rotações a cada 5 graus entre 0 e 355 graus.

Este trabalho utilizou um subconjunto de 10.000 imagens, sendo 10 imagens de cada uma das 1.000 classes de objetos fotografados, com variações no ângulo de visão de 0 a 45 graus.

A Figura 4.1 mostra um exemplo do mesmo objeto fotografado (da classe 307) sob os 10 diferentes pontos de vista considerados para o conjunto utilizado neste trabalho.



Figura 4.1 – Exemplo de variação do ângulo de rotação de 0 a 45 graus de objeto fotografado do conjunto ALOI.

A mudança de rotação dos objetos fotografados foi usada para representar a variação temporal das imagens, permitindo retratar 10 diferentes instantes temporais. Medida semelhante foi utilizada em (BUENO, 2009) e (FOGAÇA, 2016) para relacionar o ângulo de visão da fotografia com o tempo do objeto na imagem.

A extração das características das imagens foi feita pelo extrator *Color Histogram* com 512 bins para o modelo de cor RGB. Tais vetores foram usados para representar as imagens em um espaço multidimensional de 512 dimensões. A função de distância utilizada foi a função Euclidiana L2 (descrita na seção 2.3).

Foi utilizada a biblioteca de código livre Java chamada *mdscale* (*Simple Multidimensional Scaling*) disponível *online* no Github³ (ASARNOW, 2011), para implementar o processo de mapeamento dos elementos pertencentes à região de interesse da consulta para um espaço tridimensional, a fim de que pudessem ser visualizados.

O algoritmo MDS (descrito na seção 3.5) foi utilizado para representar os dados em um espaço tridimensional para visualização. Apesar deste algoritmo possuir complexidade computacional quadrática $O(n^2)$, o fato de se considerar apenas uma região de interesse dos dados a serem visualizados e não o conjunto todo, não tornou a sua utilização proibitiva.

O protótipo que possibilita a visualização dos resultados das consultas foi desenvolvido utilizando-se a *engine* Unity3D na sua versão gratuita *Personal* 2017.3⁴, aproveitando-se das funcionalidades que a ferramenta oferece para trabalhos em ambiente com 3 dimensões. Unity3D é uma ferramenta de alto desempenho para criação de jogos que gera códigos que podem ser implantados em mais de 20 sistemas operacionais diferentes, tais como *desktop*, dispositivos móveis, consoles de jogos e outros (WAGNER et al., 2016). Seus recursos têm sido usados recentemente também em trabalhos de visualização de informação (InfoVis), como os trabalhos apresentados em (WAGNER et al., 2016) e (KHALIFA et al., 2017).

Ao representar os dados recuperados em um espaço tridimensional, foi permitida a interação do usuário com a visualização em operações de zoom e rotação, já que a interação tem papel importante na descoberta de novos conhecimentos, a formação e/ou validação de hipóteses e a construção de melhores análises.

Um exemplo da vantagem de se visualizar apenas uma região do conjunto de dados, e não o conjunto todo, pode ser visto nas Figuras 4.2 e 4.3, onde a visualização de uma região de interesse definida como sendo composta por dez elementos pode ser comparada à visualização da mesma região, porém imersa em cinco mil elementos. As esferas azuis e amarela representam os 10 elementos comuns nesta comparação.

³ <https://github.com/asarnow/mdscale>

⁴ <https://unity3d.com/pt>




Figura 4.2 – Região de interesse composta por 10 elementos.




Figura 4.3 – Região de interesse composta por 5000 elementos.

Nota-se que, além da clara dificuldade na visualização de grande quantidade de dados, ao mapear 5.000 elementos o erro inserido (*stress*) foi maior do que o erro inserido ao mapear apenas 10, prejudicando a distribuição dos elementos no espaço mapeado.

Os valores de estresse encontrados foram 0,1459 para a consulta com região de interesse de 5000 elementos e apenas 0,0063 para consulta com região de interesse de 10 elementos.

Nas Figuras 4.4 e 4.5 a ampliação da visão por meio de operações de zoom permitiu destacar parte do conjunto mapeado para que fossem observados os mesmos 10 elementos representados na Figura 4.2, onde é possível perceber que ocorreram sobreposições de elementos com o aumento do erro no mapeamento.




Figura 4.4 – Região de interesse composta por 5000 elementos - Detalhe.




Figura 4.5 – Região de interesse composta por 5000 elementos - Detalhe.

Um comparativo entre os erros inseridos ao mapear conjuntos com 10, 100, 1.000 e 10.000 elementos pode ser visto na Figura 4.6.

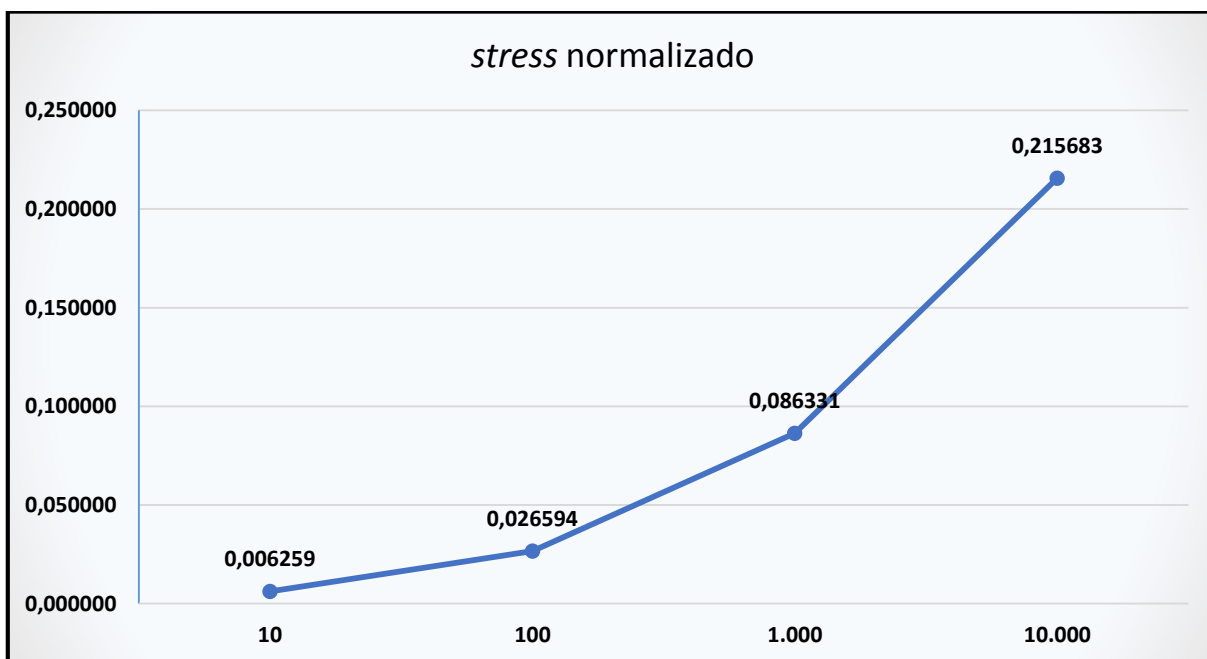


Figura 4.6 – Aumento do erro inserido no processo de mapeamento para diferentes quantidades de elementos.

Nestes casos foi possível observar que, à medida em que o número de elementos aumenta, mais prejudicada é a distribuição dos dados, uma vez que o erro inserido também aumenta com a quantidade de elementos mapeados. Assim, quanto menor o *stress*, melhor a representação dos dados e, quanto maior o *stress*, maior a distorção inserida.

Desta maneira, mostra-se como uma boa abordagem a de particionar a análise por regiões de interesse menores sobre o conjunto de dados.

A seguir são descritos alguns cenários estudados cujo foco, a priori, é corroborar com a afirmação de que a análise guiada pela informação visual facilita a compreensão dos dados. Neste sentido é importante observar as vantagens de se visualizar apenas uma região (região de interesse) em vez de visualizar o conjunto todo dos dados.

4.3 Consulta k-NN simples

A visualização dos dados recuperados em uma consulta k-NN simples, cuja região de interesse foi definida pelo valor informado para k , pode ser vista na Figura 4.7. Neste cenário, a região de interesse foi determinada como sendo os sete vizinhos mais próximos (7-NN) da imagem usada como centro de busca.

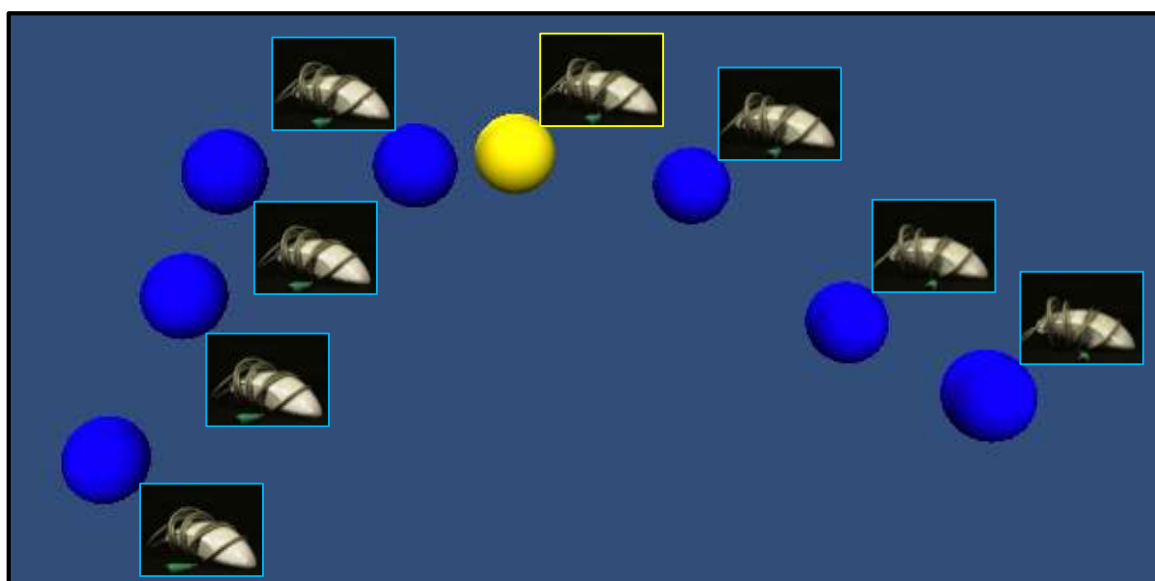


Figura 4.7 – Visualização de consulta k-NN simples.

Nota-se alguns dos elementos usados para exibir os resultados das consultas no protótipo para visualização: a esfera amarela representa o elemento usado como centro de busca da consulta e as esferas azuis representam os elementos recuperados como resultado, dispostos no espaço mapeado 3D.

Esta consulta usou como centro de busca a imagem “457_r20.png” e recuperou sete imagens da classe 457: “457_r15.png”, “457_r25.png”, “457_r10.png”, “457_r5.png”, “457_r30.png”, “457_r0.png” e “457_r35.png”.

Cada variação do ângulo de visão dos objetos fotografados foi usada para representar os tempos das imagens. Assim, esta consulta retornou as imagens do mesmo objeto fotografado (um “mouse”), nos tempos 15, 25, 10, 5, 30, 0 e 35, respectivamente.

Neste trabalho, uma consulta simples aos k -vizinhos mais próximos delimita a região de interesse como sendo formada pelos k elementos retornados e exibe somente esta região.

Para melhor ilustrar a descrição deste cenário, na Figura 4.7 foram exibidas as *thumbnails* das imagens que cada elemento representa próximas das esferas da visualização. No protótipo para visualização, foram implementadas opções que permitem que o usuário veja a imagem que cada uma das esferas no espaço mapeado representa, além de obter as informações sobre o nome do arquivo da imagem, o tempo que este elemento representa, a classe da imagem, a distância ao centro de busca e o caminho físico do arquivo no disco de armazenamento.

A matriz de distâncias entre os elementos recuperados nesta consulta possui valores como apresentados na Tabela 4.1.

Tabela 4.1 – Matriz de distâncias (7-NN).

	t=20	t=15	t=25	t=10	t=5	t=30	t=0	t=35
t=20	0.0	3.000	4.358	5.830	7.000	7.348	9.486	9.591
t=15		0.0	6.164	4.123	5.477	9.000	7.810	10.908
t=25			0.0	9.327	10.295	4.582	12.369	7.000
t=10				0.0	3.316	12.165	5.830	14.000
t=5					0.0	12.609	4.123	14.317
t=30						0.0	14.142	3.741
t=0							0.0	15.620
t=35								0.0

Esta matriz pode ser entendida como a representação matemática da percepção humana de similaridade entre os elementos que compõem o resultado da consulta, onde números mais próximos de zero indicam elementos com maior similaridade entre si e, à medida em que os números aumentam, observa-se uma diminuição do grau de similaridade. Para a representação neste trabalho, ponderou-se exibir os valores da matriz de distâncias com apenas três casas decimais.

As imagens recuperadas nesta consulta podem ser vistas na Figura 4.8. A imagem com borda amarela representa o centro de busca e as imagens com bordas azuis compõem a resposta da consulta.

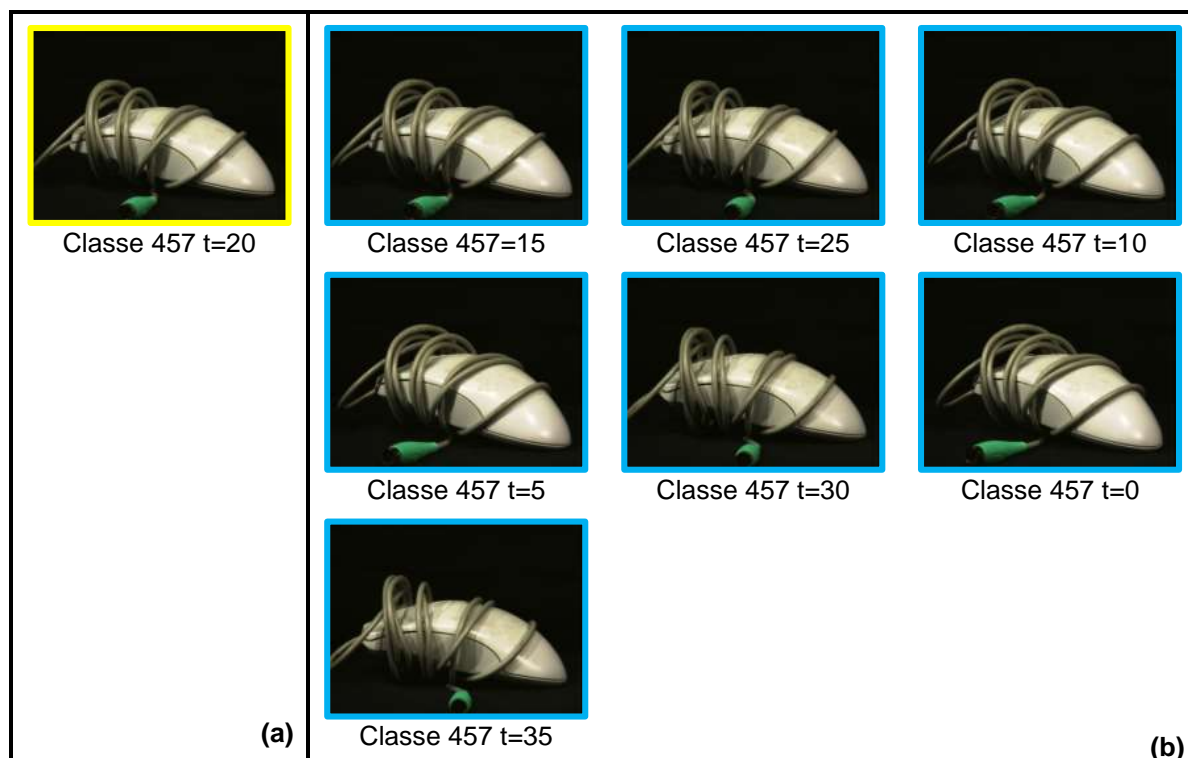


Figura 4.8 – Imagens retornadas em consulta k-NN ($k=7$). Em (a) a imagem usada como centro de busca. Em (b) o conjunto resposta da consulta.

4.3.1 Consulta k-NN: expansão com % k de elementos

Algumas vezes, além da distribuição das imagens recuperadas e do centro de busca (mostrados na visualização do k-NN simples), pode ser necessário conhecer como as imagens da resposta da consulta relacionam-se com as outras imagens próximas a elas.

Assim, propôs-se expandir a região de visualização para mostrar a distribuição dos seus elementos, permitindo ao usuário conhecer outras imagens próximas que pudessem ser consideradas relevantes para o estudo realizado. Tal expansão foi feita aplicando-se um valor percentual sobre o número k de elementos da consulta.

Em um novo cenário a região de interesse dos dados pesquisados foi definida como sendo formada por um acréscimo de 60% ao valor inicial de k , para $k=7$. Utilizou-se a imagem no tempo $t=20$ da classe 457 como centro de busca.

Após a execução da consulta, foram visualizados onze elementos (7-NN acrescido de 60%). São as imagens dos tempos 15, 25, 10, 5, 30, 0, 35, 40 e 45 pertencentes à classe 457 e também as imagens dos tempos 25 e 35 da classe 682.

Ao visualizar o resultado desta consulta (exibido na Figura 4.9), o usuário pode ver os elementos que compõem o conjunto dos sete vizinhos mais próximos (representado por esferas azuis), destacando-se os elementos acrescentados à região de interesse (4 esferas vermelhas) e, ao analisar cada uma das suas imagens, pode decidir considerar, ou não, os elementos acrescentados à visualização como sendo relevantes para a pesquisa.

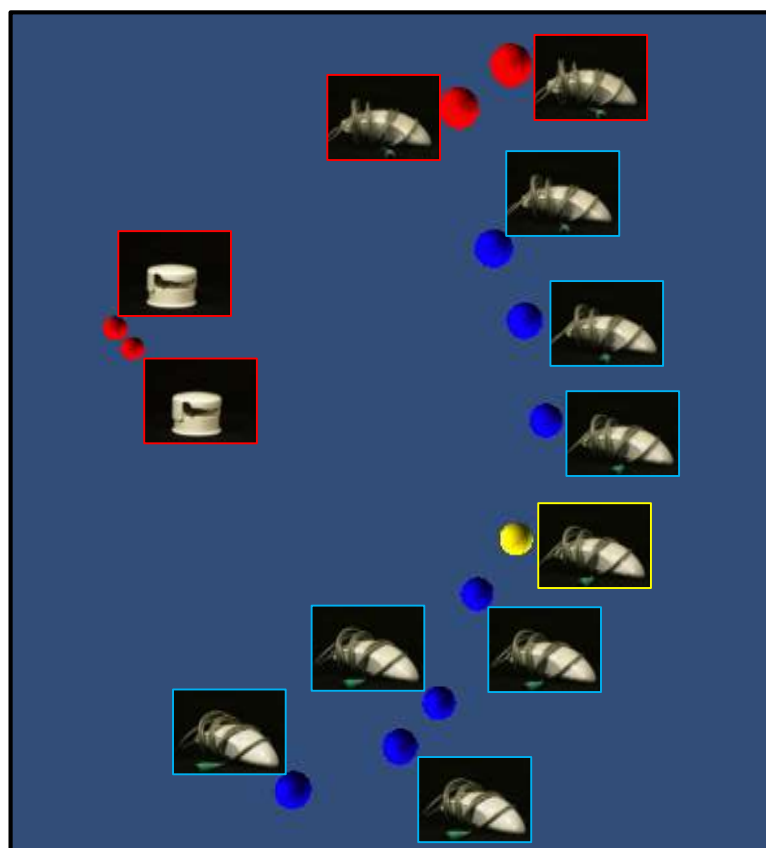


Figura 4.9 – Visualização de consulta com alteração da região de interesse com percentual de aumento.

As esferas vermelhas representam elementos extras adicionados à visualização e fazem parte da região de interesse definida. Elas são exibidas quando a região de interesse foi modificada com um dos parâmetros disponíveis no protótipo, neste caso, a expansão com o % sobre o número k de elementos.

É possível identificar visualmente que dois dos elementos acrescentados à região de interesse nesta consulta (as esferas vermelhas na parte superior direita da visualização) pertencem ao mesmo agrupamento dos elementos retornados pelos k -vizinhos mais próximos do centro de busca, ou seja, são imagens do mesmo objeto

fotografado (um *mouse*). Os outros dois elementos (esferas vermelhas à esquerda) pertencem a um agrupamento diferente e são imagens de outro objeto fotografado.

A interação com a visualização por meio da aplicação de zoom e/ou rotação, permite entender melhor como os elementos estão distribuídos no espaço mapeado, além de tornar possível identificar visualmente a relação de distância entre eles.

O conjunto de imagens visualizadas nesta consulta é exibido na Figura 4.10. O centro de busca está destacado com borda amarela, as imagens com bordas azuis representam a resposta da consulta e as imagens com bordas vermelhas são as imagens acrescentadas à região de interesse para visualização.

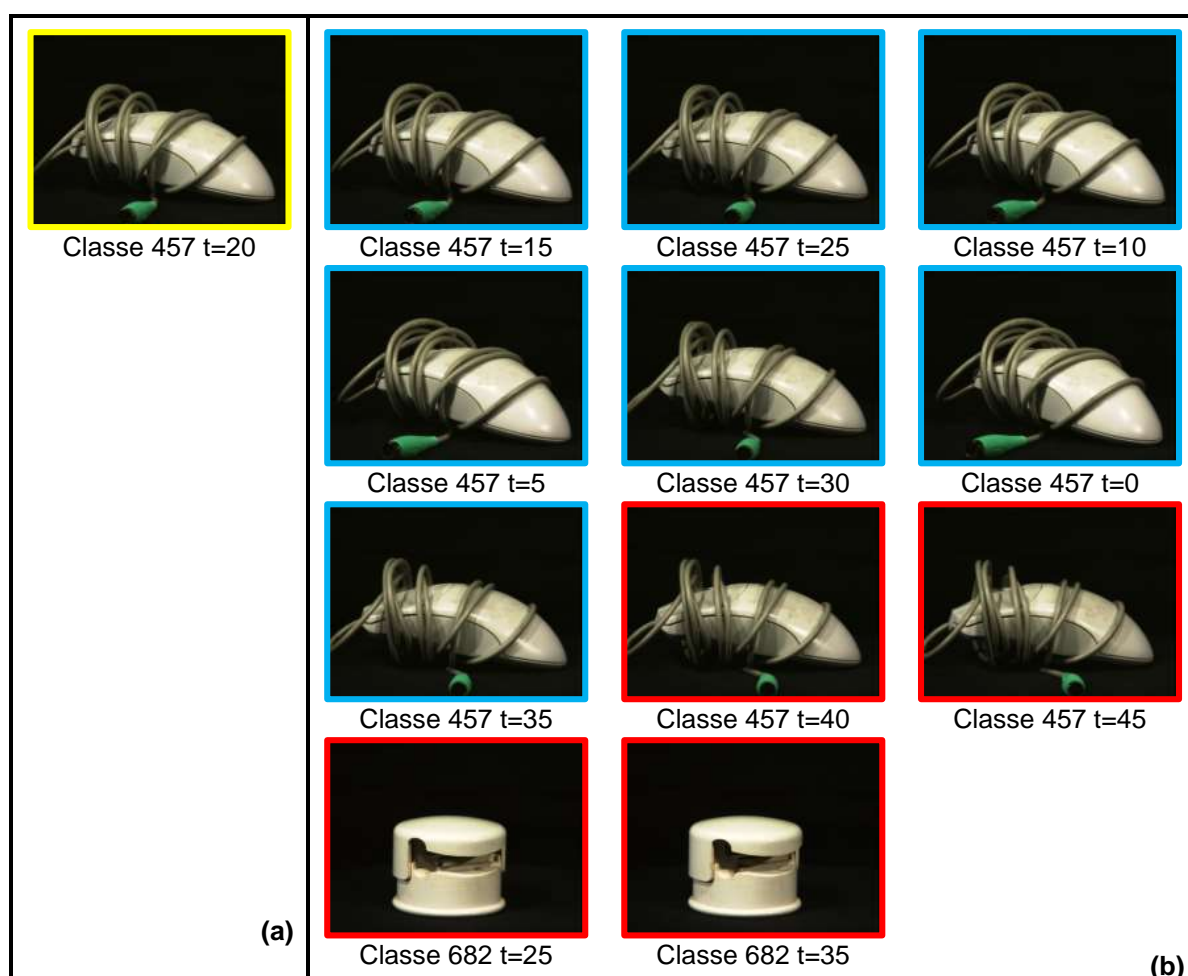


Figura 4.10 – Imagens visualizadas em consulta com alteração da região de interesse com percentual de aumento de k . Em (a) a imagem usada como centro de busca. Em (b) o conjunto de imagens visualizadas.

4.3.2 Consulta k-NN: expansão por % do raio do k-NN simples

Aumentar a região de visualização apenas considerando o número de elementos retornados pode não ser o ideal, pois não leva em conta a distribuição dos elementos na região e, independentemente da região visualizada ser densamente povoada ou não, o número de objetos a serem incluídos para visualização é sempre fixo.

A fim de minimizar esse problema, a próxima proposta considera um aumento em percentual sobre o valor do raio da consulta k-NN. Acrescenta-se um percentual à distância do vizinho mais afastado do centro de busca, criando um raio que delimita a região de interesse. Desta forma, a consulta k-NN é convertida em uma consulta por abrangência com o raio expandido, o que faz com que a distribuição local dos dados na região visualizada seja levada em conta para determinar o número de elementos que serão visualizados.

Caso a consulta esteja sendo realizada em uma região com alta densidade de elementos, mais do que k elementos podem ser visualizados e, em uma região esparsa, pode-se visualizar menos elementos do que o valor indicado para k .

Em um novo cenário, considerou-se o raio da consulta k-NN para expandir a região de interesse. Um acréscimo de 100% à distância do vizinho mais afastado foi usado na execução de uma consulta que usou a imagem do tempo $t=20$ da classe 457 como centro de busca para selecionar seus sete vizinhos mais próximos.

Embora tenha sido informado um valor inicial para $k=7$, esta consulta permitiu visualizar nove elementos e, na visualização, aqueles que foram acrescentados pela nova região de interesse estão destacados (esferas vermelhas) dos sete vizinhos mais próximos (esferas azuis) do centro de busca.

Na Figura 4.11, a distância d ao sétimo vizinho mais próximo da consulta k-NN simples foi incrementada em 100% para definir o raio estimado r que demarcou a nova região de interesse, acrescentando novos elementos na área a ser visualizada.




Figura 4.11 – Visualização de consulta com alteração da região de interesse com percentual de aumento do raio do k-NN simples.

A análise visual permite notar que, ao expandir a região de interesse pelo raio do k-NN, apenas elementos da mesma classe foram adicionados à visualização. Eles são os elementos que representam as imagens dos tempos 15, 25, 10, 5, 30, 0, 35, 40 e 45 da classe 457.

As imagens estão exibidas na Figura 4.12, onde o centro de busca foi apresentado com borda amarela, os sete vizinhos mais próximos possuem bordas azuis e as imagens destacadas com bordas vermelhas são as imagens que foram acrescentadas à nova região de interesse, calculada pelo acréscimo de percentual do raio da consulta k-NN simples.

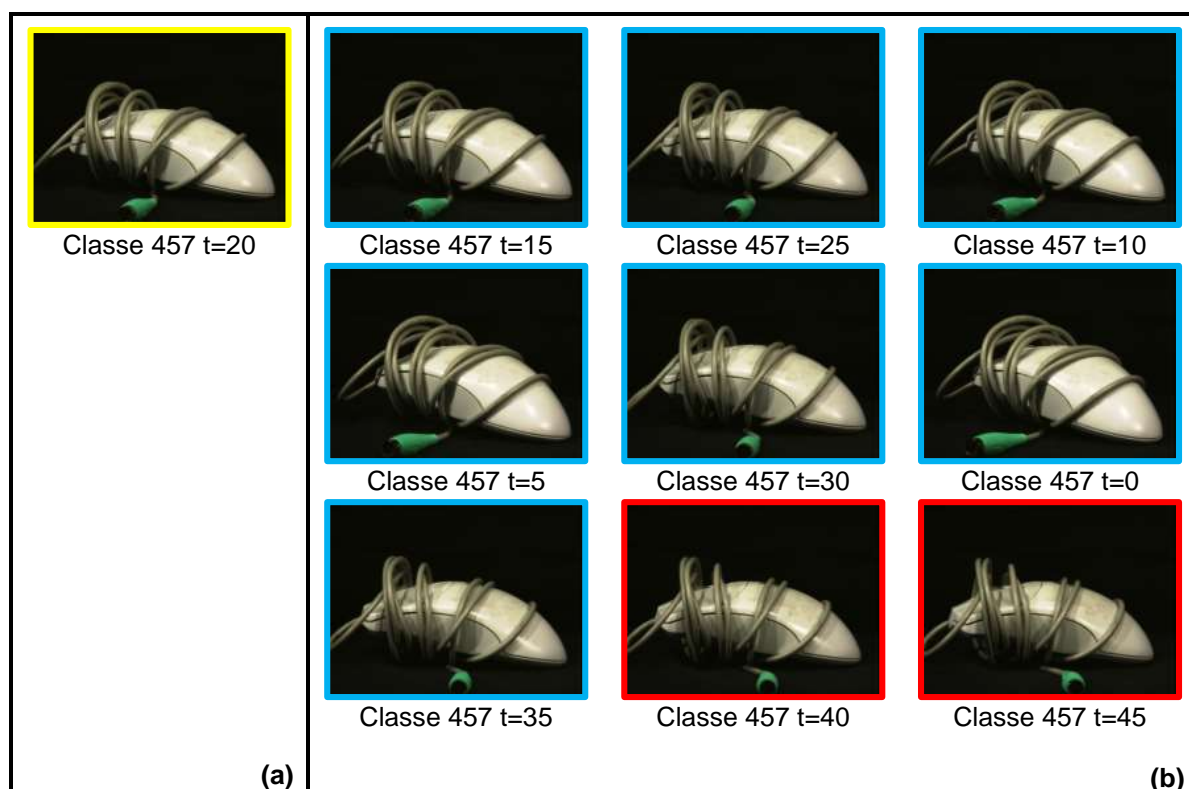


Figura 4.12 – Imagens visualizadas em consulta com alteração da região de interesse com percentual de aumento do raio do k-NN simples.

Novamente considerou-se um acréscimo sobre o raio do k-NN para expandir a região de interesse da consulta. A imagem do tempo $t=30$ da classe 928 foi usada como centro de busca para encontrar os sete vizinhos mais próximos em uma consulta que também considerou 100% de acréscimo à distância do vizinho mais afastado.

Apesar do valor para $k=7$ ter sido informado, a expansão da região de interesse pelo acréscimo do raio do k-NN permitiu visualizar 19 elementos, sendo 9 da mesma classe do centro de busca e outros 10 elementos de outra classe próxima da região. Na Figura 4.13 os elementos acrescentados foram destacados (esferas vermelhas) dos sete vizinhos mais próximos (esferas azuis) do centro de busca.




Figura 4.13 – Visualização de consulta com alteração da região de interesse com percentual de aumento do raio do k-NN simples.

Ao visualizar, é possível perceber que o raio do k-NN expandiu a região de interesse de modo que elementos de agrupamentos diferentes fossem adicionados à visualização, por se tratar de uma região de alta densidade de elementos. São as imagens dos tempos 15, 25, 20, 35, 0, 10, 45, 5 e 40 da classe 928 e as imagens dos tempos 20, 10, 45, 0, 15, 30, 40, 25, 35 e 5 da classe 300.

A Figura 4.14 exibe as imagens visualizadas, destacando o centro de busca com borda amarela, os sete vizinhos mais próximos com bordas azuis e as imagens acrescentadas à nova região de interesse com bordas vermelhas.

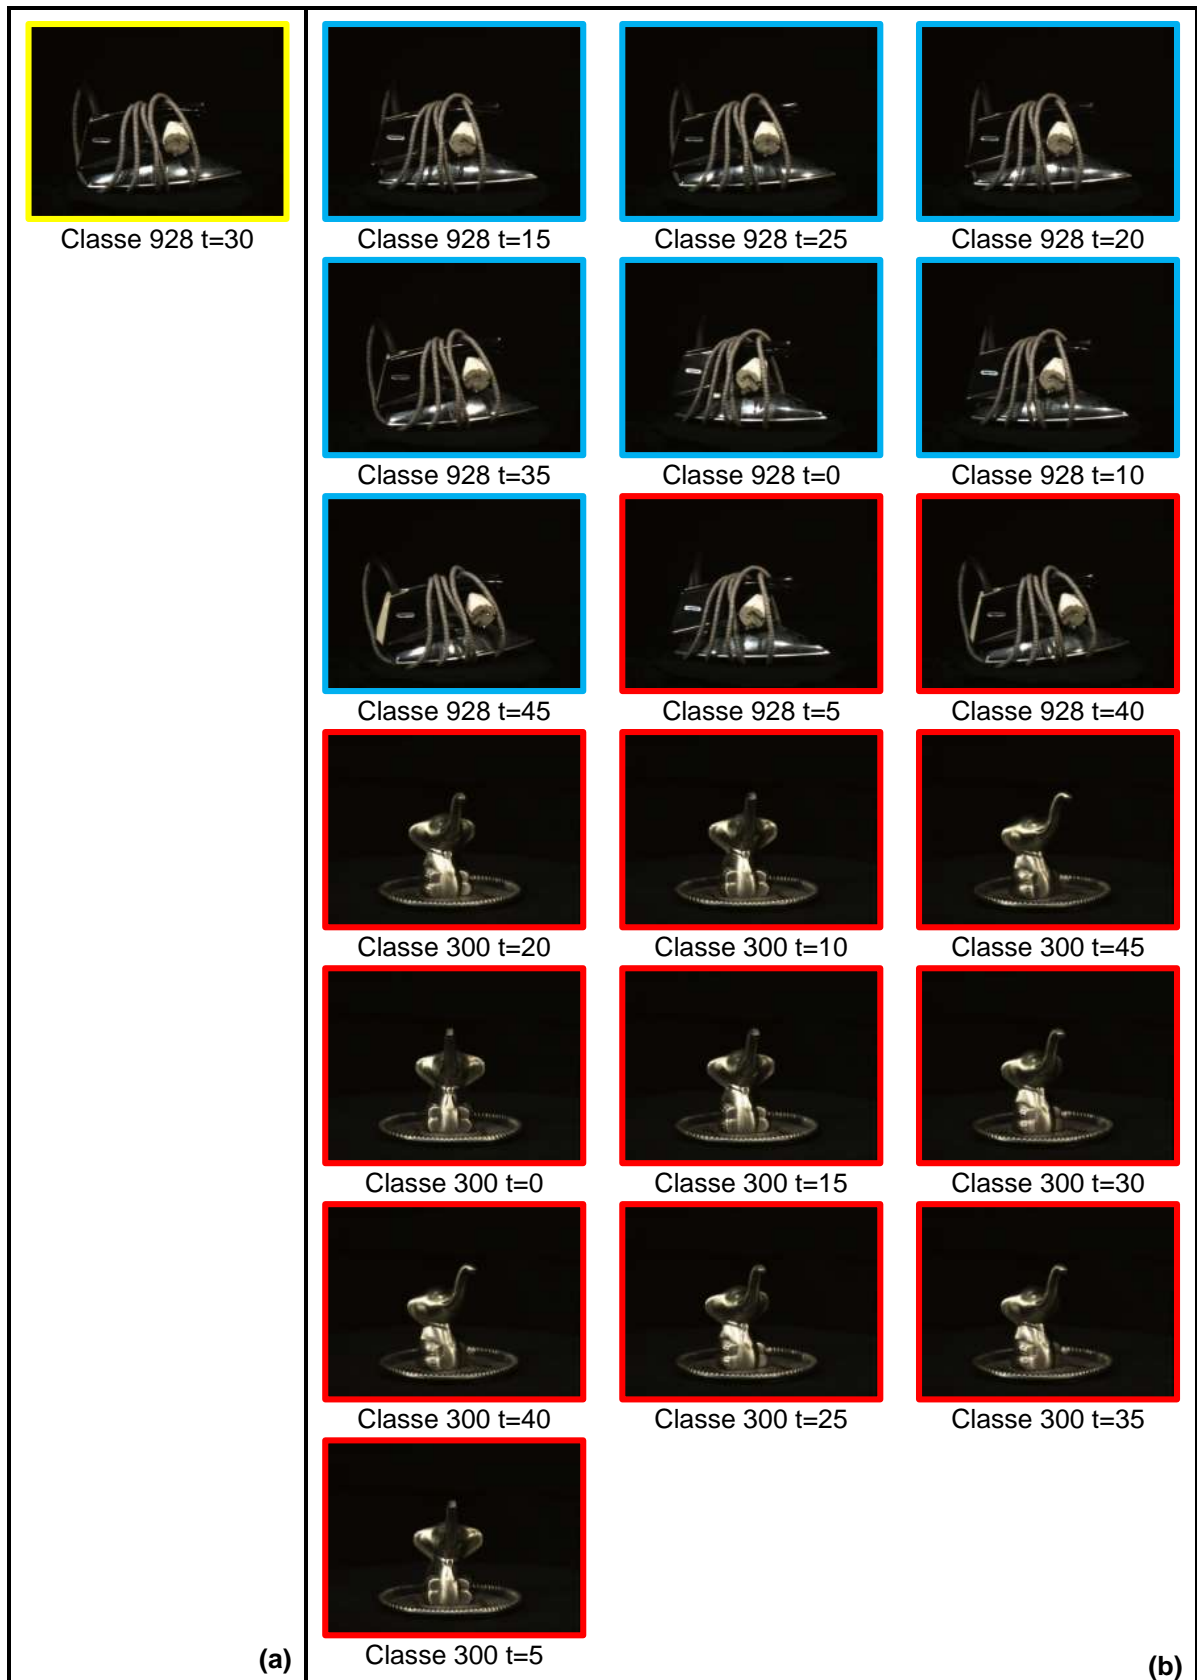


Figura 4.14 – Imagens visualizadas em consulta com alteração da região de interesse com percentual de aumento do raio do k-NN simples.

4.4 Uso da dimensão fractal para delimitar a região de interesse

Ao usar a dimensão fractal, não apenas a distribuição dos dados da região de interesse é levada em consideração para expandir a área visualizada, mas também a distribuição média dos elementos no conjunto todo.

No protótipo criado foi possível delimitar a região de interesse da consulta com o valor da dimensão fractal. Nestes cenários as consultas passam a considerar um raio estimado para definir a região de interesse e recuperar os elementos. Este raio r é calculado como mostrado na Equação 4.1, proposta em (ARANTES et al., 2003).

$$r = r1. \exp\left(\frac{\log(k(k - 1)) - \log(k1(k1 - 1))}{D}\right) \quad (4.1)$$

Nesta equação, $r1$ representa o diâmetro do conjunto de dados (a maior distância encontrada entre os elementos), k é o número de elementos que se deseja buscar, $k1$ representa o número total de elementos e D é o valor informado da dimensão fractal. Tanto o diâmetro como a dimensão fractal são calculados uma única vez para o conjunto. A dimensão fractal tende a ser invariante ao tamanho do conjunto de dados, ainda que sejam feitas inserções ou exclusões de dados (ARANTES et al., 2003).

Um fractal pode ser entendido como sendo um conjunto de dados que possuem dentro de si, cópias menores de si mesmos em todas as escalas, caracterizando o que é conhecido como autossimilaridade, ou seja, partes do fractal são semelhantes (exatamente ou estatisticamente) a todo o fractal (FALOUTSOS; KAMEL, 1994).

O uso da dimensão fractal para estimar o raio de uma consulta aos k -vizinhos mais próximos no conjunto de dados (ARANTES et al., 2003) converte tal consulta k -NN em uma consulta por abrangência.

Considerando-se o conjunto como um todo e o valor do raio médio de uma consulta aos k -vizinhos mais próximos, caso a região onde está sendo realizada a consulta tenha uma alta densidade de elementos, mais do que k elementos devem ser visualizados.

Considere então, uma consulta k-NN simples aos cinco vizinhos mais próximos de um dado centro de busca em uma região com alta densidade de elementos.

Esta consulta recupera os cinco vizinhos mais próximos mas, como não contempla a região do entorno, pode desprezar elementos importantes para o contexto pesquisado. Este caso está ilustrado na Figura 4.15 onde, ao visualizar apenas as cinco imagens mais próximas do centro de busca (pontos azuis), deixa-se de visualizar imagens também próximas que podem ser importantes.

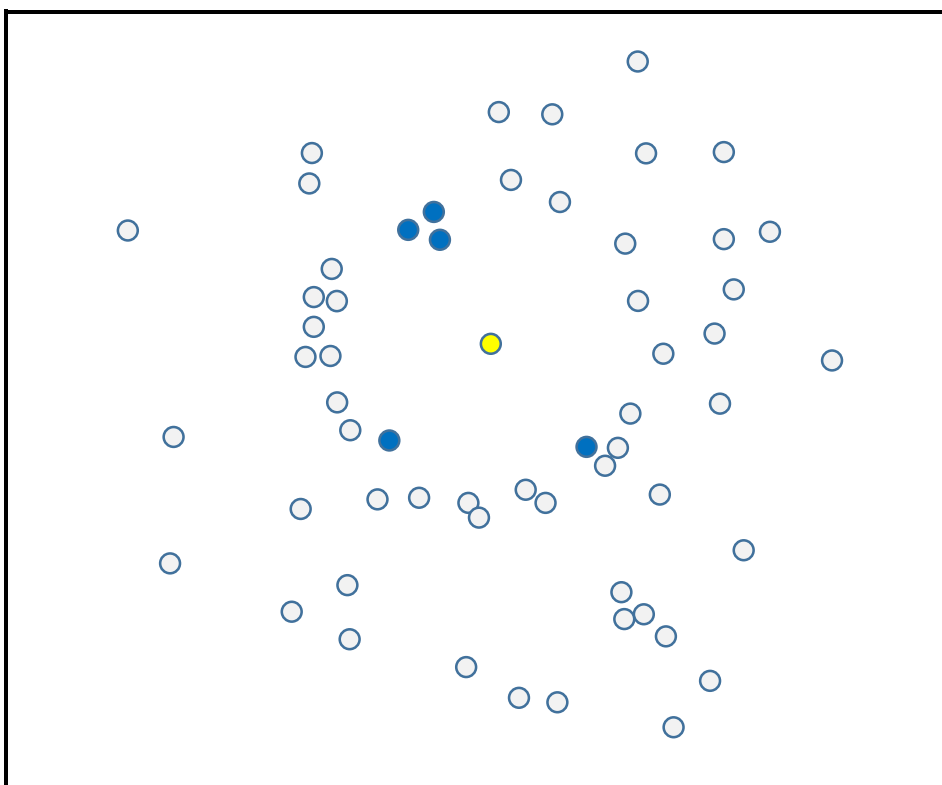


Figura 4.15 – Consulta 5-NN em uma região densa.

Ao delimitar a região de interesse da consulta com um raio estimado, uma consulta aos cinco vizinhos mais próximos (5-NN) executada em uma região densa de elementos tende a retornar mais elementos do que o valor definido inicialmente para k , uma vez que passa a considerar todos os elementos da região delimitada por este raio estimado.

A Figura 4.16 ilustra este caso onde os pontos vermelhos representam os elementos acrescentados à visualização por estarem dentro do raio estimado que delimita a região de interesse.




Figura 4.16 – Raio estimado pela dimensão fractal para 5-NN em uma região densa.

Por outro lado, caso a região pesquisada tenha uma distribuição esparsa, menos elementos serão visualizados. Isso propicia um melhor entendimento da distribuição dos dados na região visualizada.

Considere agora uma consulta aos cinco vizinhos mais próximos de um dado centro de busca executada em uma região de distribuição esparsa de elementos. A Figura 4.17 ilustra este cenário, onde os pontos azuis representam os elementos recuperados na consulta.

Nota-se que esta consulta traz elementos de agrupamentos diferentes como resposta, pelo fato de ser realizada em uma região onde a distribuição dos elementos é esparsa.




Figura 4.17 – Consulta 5-NN em uma região esparsa.

Em contrapartida, uma consulta aos cinco vizinhos mais próximos executada em uma região de distribuição esparsa de elementos, mas com uso da dimensão fractal, tende a descartar os elementos mais distantes do centro de busca, que poderiam ser elementos de outro agrupamento e não importantes para o resultado.

Este caso está ilustrado na Figura 4.18, onde o raio definido pela dimensão fractal delimitou a região de interesse de modo que somente dois elementos fossem recuperados pela consulta e visualizados.




Figura 4.18 – Raio estimado pela dimensão fractal para 5-NN em uma região esparsa.

Assim, utilizar dimensão fractal do conjunto, pode aumentar ou diminuir o número de elementos visualizados em comparação ao valor inicialmente informado pelo usuário para o k da consulta, já que a região de interesse neste caso, passa a considerar os elementos que estão dentro da área delimitada pelo raio estimado, levando em conta não apenas a distribuição local dos dados na região visualizada mas também a distribuição do conjunto todo.

4.4.1 Estimativa do raio de consulta: regiões densas

Um novo cenário considerou a região de interesse da consulta como sendo delimitada pela dimensão fractal do conjunto de dados. A imagem do tempo $t=30$ da classe 759 foi usada como centro de busca para consultar os seus cinco vizinhos mais próximos (5-NN).

Ao visualizar a resposta desta consulta, ainda que o valor indicado para k tenha sido cinco, nove elementos foram exibidos. São os elementos que representam as imagens dos tempos 25, 35, 0, 40, 5, 10, 15, 20 e 45 da classe 759. Esta consulta pode ser vista na Figura 4.19.

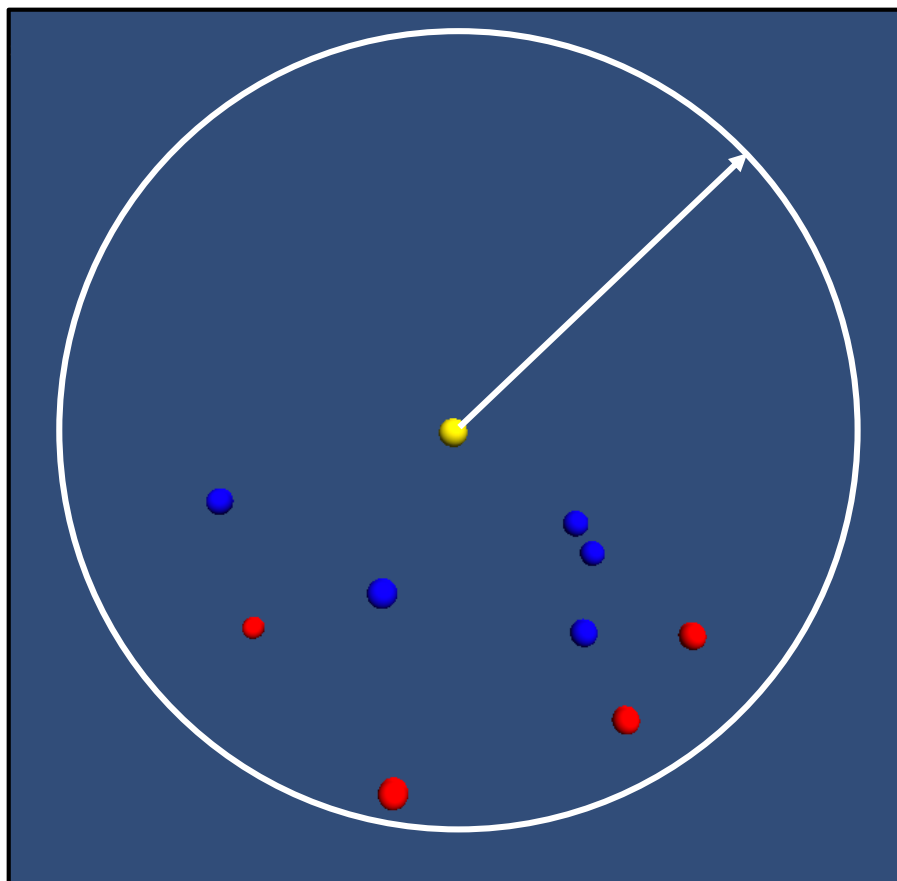


Figura 4.19 – Elementos adicionados à região de interesse com uso da dimensão fractal.

Na visualização é possível identificar os nove elementos da região demarcada pelo raio estimado a partir do valor da dimensão fractal.

Os elementos que correspondem ao resultado da consulta estão representados pelas esferas azuis e as esferas vermelhas representam os elementos acrescentados à área visualizada para compor a região de interesse. Cabe ao usuário analisar as imagens e decidir se os elementos acrescentados são relevantes para a pesquisa ou não.

O valor da dimensão fractal para o conjunto de dados usado é 3,338125 e o diâmetro calculado é 444,6819087842455.

As imagens visualizadas nesta consulta são exibidas na Figura 4.20 onde o centro de busca foi destacado com borda amarela, os cinco vizinhos mais próximos possuem bordas azuis e as imagens acrescentadas à região de interesse pela dimensão fractal, possuem bordas vermelhas.




Figura 4.20 – Imagens visualizadas em consulta com alteração da região de interesse pela dimensão fractal. Em (a) a imagem usada como centro de busca. Em (b) o conjunto de imagens visualizadas.

Em um novo cenário, considerou-se um valor para $k=9$ e a imagem no tempo $t=15$ da classe 207 como centro de busca em uma consulta cuja região de interesse foi determinada pelo uso da dimensão fractal.

Em relação ao conjunto como um todo, uma consulta aos 9 vizinhos mais próximos apresenta um raio médio estimado em 6,4255.

Considerando-se o elemento usado como centro de busca (207 $t=15$) e a utilização desse raio médio estimado, verificou-se que esta consulta retornou mais do que 9 elementos, o que indica que o centro de consulta está em uma região mais densa, em comparação com o conjunto todo.

Na visualização foram exibidas 17 imagens: as que representam os respectivos tempos 20, 10, 25, 30, 0, 35, 40, 5 e 45 da classe 207, as imagens dos tempos 0, 25, 35, 20, 15 e 5 da classe 347, o tempo 25 da classe 756 e o tempo 30 também da classe 347. Este resultado é exibido na Figura 4.21.




Figura 4.21 – Elementos adicionados à região de interesse com uso da dimensão fractal.

Na visualização do resultado, as esferas azuis representam os nove elementos da consulta que foram determinados pelo k e as esferas vermelhas representam os elementos acrescentados à visualização e que estão posicionados dentro do raio estimado.

Ao visualizar, nota-se que os elementos acrescentados pertencem à outra classe daquele usado como centro de busca, o que indica que, considerando a média do conjunto todo, tais imagens estão dentro do raio de uma consulta aos 9 vizinhos mais próximos.

As imagens visualizadas são potencialmente interessantes para o resultado da consulta. Elas são exibidas na Figura 4.22, onde o centro de busca está destacado com borda amarela, os vizinhos mais próximos estão com bordas azuis e as imagens com bordas vermelhas são aquelas acrescentadas à região de interesse pelo raio estimado a partir da dimensão fractal.

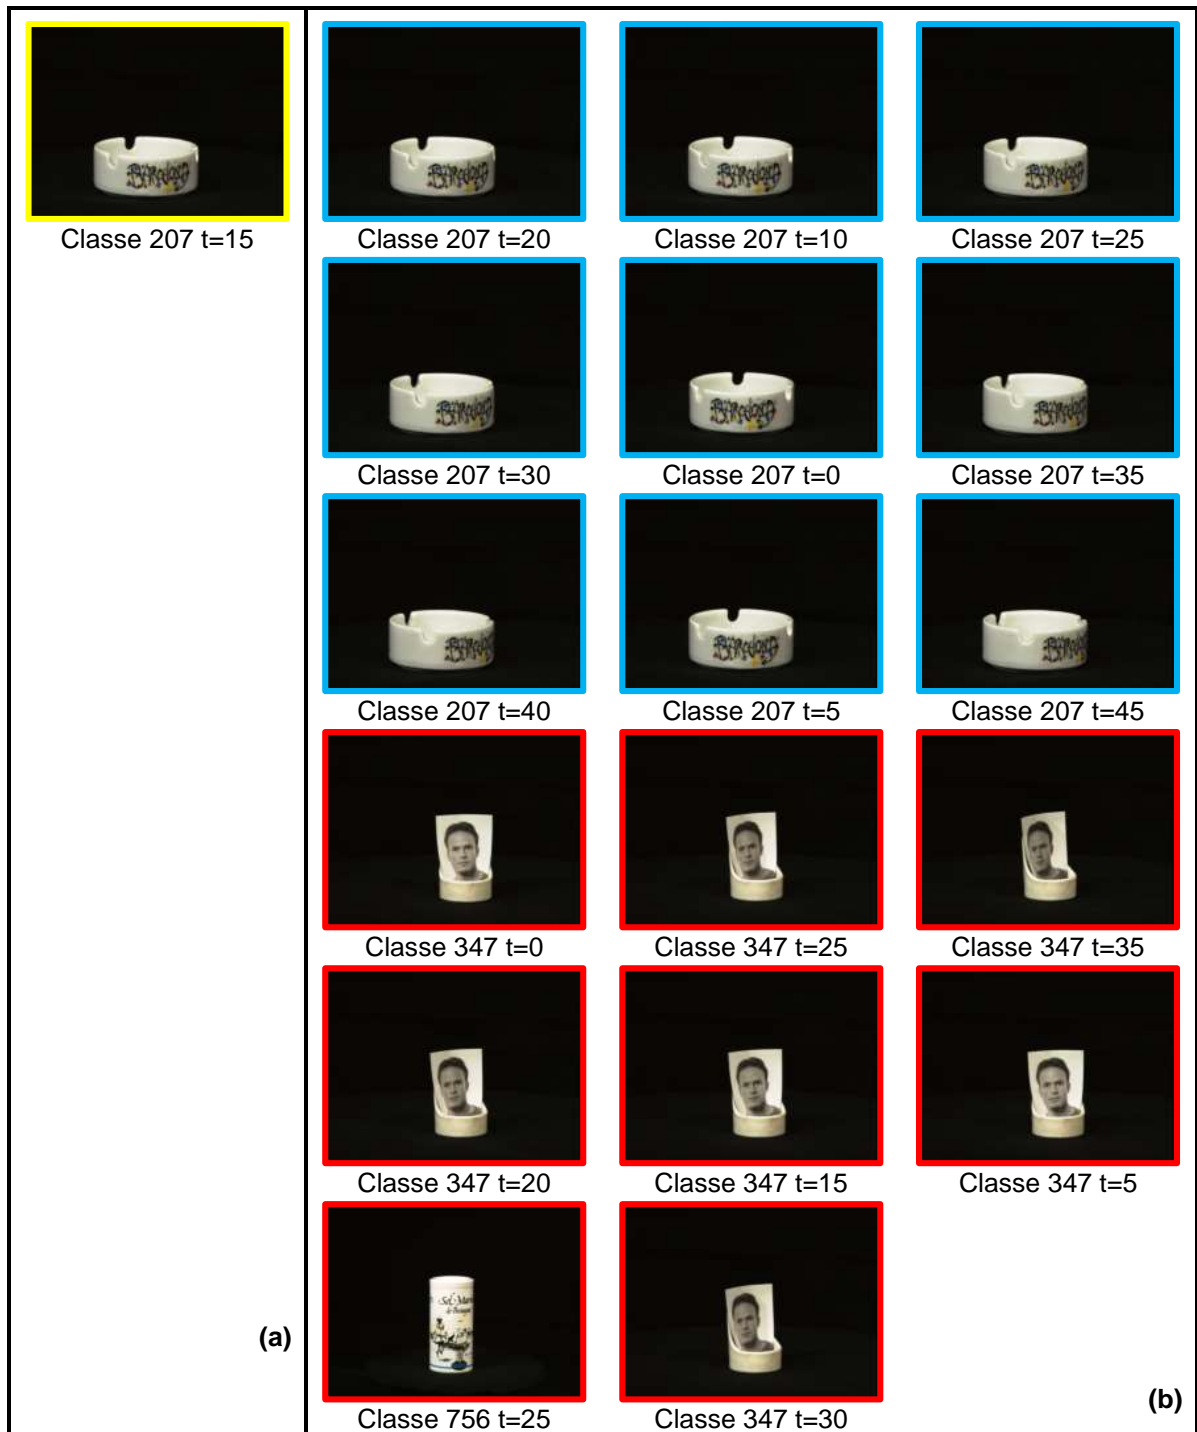


Figura 4.22 – Imagens visualizadas em consulta com alteração da região de interesse com percentual de aumento pela dimensão fractal. Em (a) a imagem usada como centro de busca e em (b) o conjunto resultado.

4.4.2 Estimativa do raio de consulta: regiões esparsas

Algumas vezes, o raio estimado que demarca a região de interesse pode fazer com que a resposta da consulta seja um conjunto com menor quantidade de elementos do que o valor informado inicialmente para k .

Para analisar tal afirmação, o resultado de uma consulta simples aos 12 vizinhos mais próximos foi comparado com o resultado de uma consulta com região de interesse delimitada pelo raio estimado pela dimensão fractal. Em ambas consultas o centro de busca informado foi a imagem do tempo $t=30$ da classe 293.

A primeira consulta traz as imagens dos tempos 25, 35, 20, 5, 40, 15, 10, 45 e 0 da classe 293 e as imagens dos tempos 0, 15 e 5 da classe 543, exibidas na Figura 4.23.

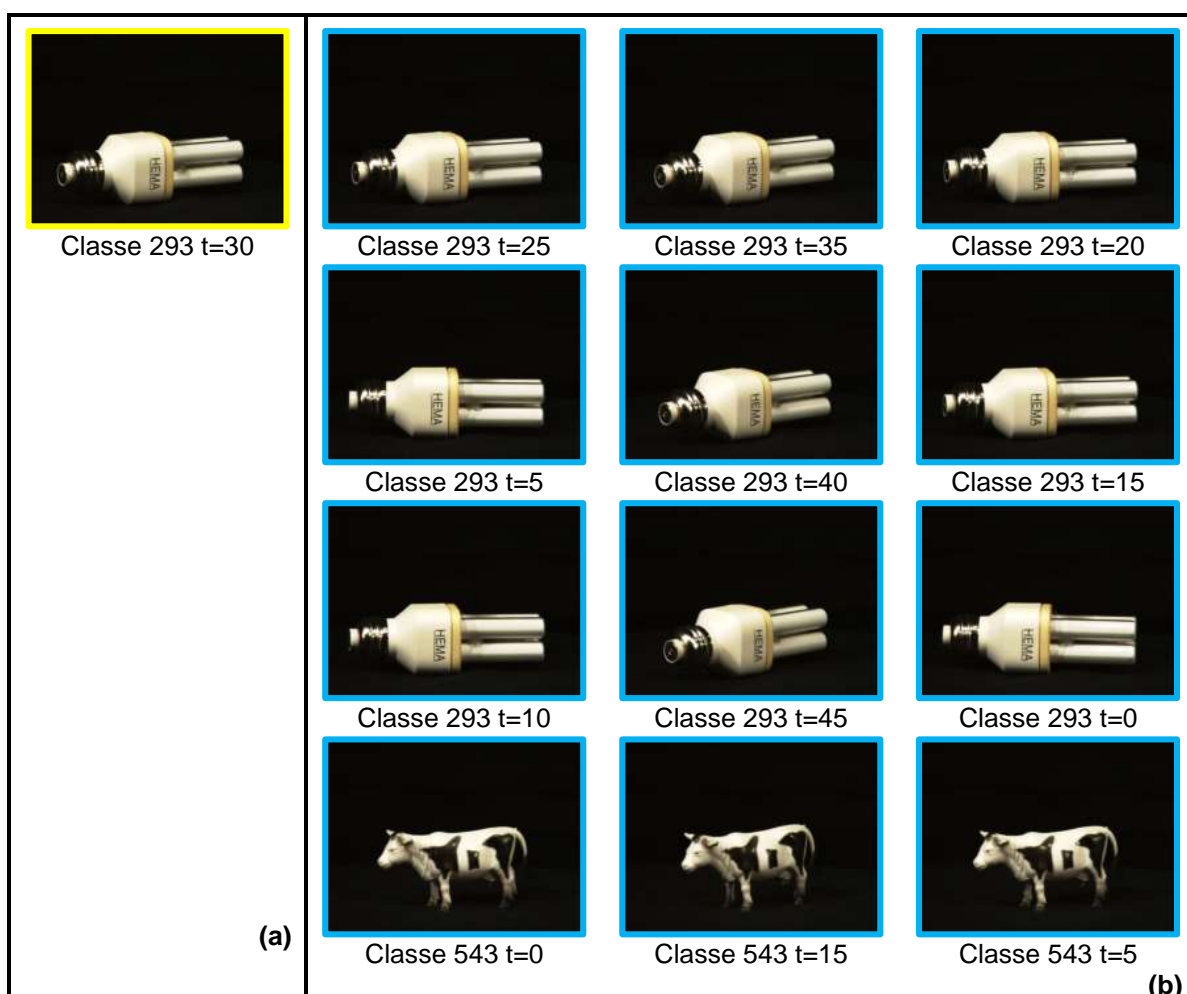


Figura 4.23 – Imagens retornadas em consulta k-NN ($k=12$). Em (a) a imagem usada como centro de busca. Em (b) o conjunto resposta da consulta.

Ao executar novamente a consulta com a região de interesse delimitada pela dimensão fractal, 9 elementos compõem o conjunto resultado e, ao analisá-los visualmente, nota-se que aqueles pertencente à classe 543 não foram incluídos no resultado por estarem fora da região de interesse demarcada pelo raio. Este resultado pode ser visualizado na Figura 4.24, onde foram exibidas as imagens eliminadas quando consulta usou dimensão fractal.

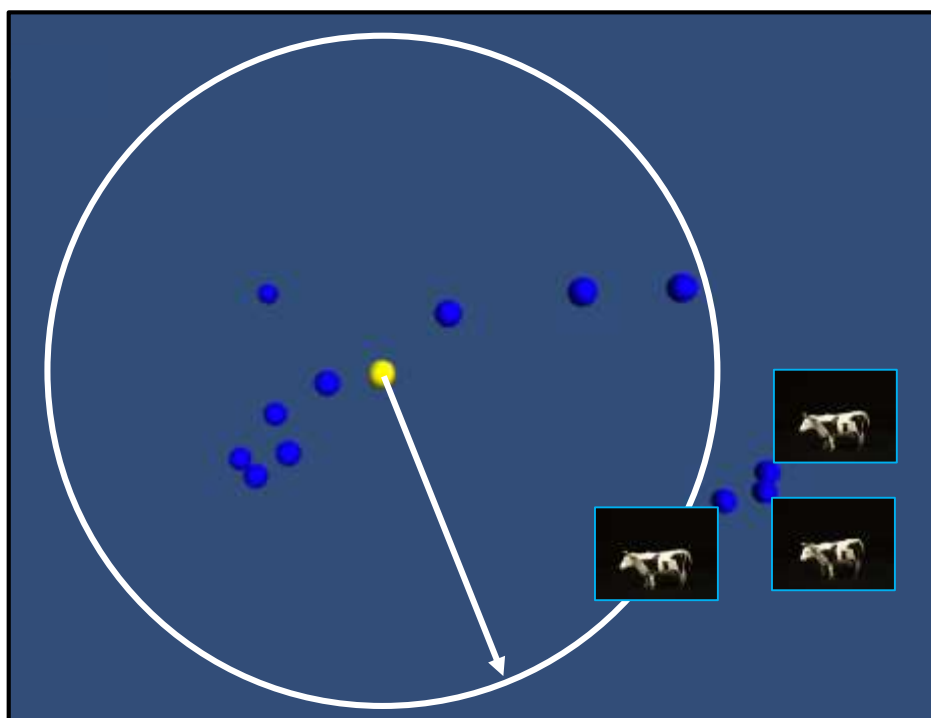


Figura 4.24 – Exclusão de elementos da região de interesse com uso da dimensão fractal. Em destaque, os elementos eliminados do resultado.

4.4.3 Expansão do raio em consultas com dimensão fractal

Nas consultas usando dimensão fractal foi possível considerar um valor maior de k para o cálculo do raio que delimitou a região de interesse da consulta. Nestes casos, o valor usado como um dos parâmetros de entrada na equação que define o raio estimado (Equação 4.1) foi acrescentado em percentual, resultando em um novo raio e, conseqüentemente, em uma nova região de interesse a ser visualizada.

Considere uma consulta sem uso da dimensão fractal para encontrar os cinco vizinhos mais próximos (5-NN) em uma região com alta densidade de elementos e com acréscimo de 100% do número de elementos retornados.

A visualização desta consulta mostra o dobro de elementos informados inicialmente para k ($k=5$ com acréscimo de 100% sobre o número de elementos retornados). Contudo, ainda que um valor maior de k tenha sido considerado, pode-se deixar de visualizar elementos importantes e agrupamentos próximos da região da consulta. A Figura 4.25 ilustra este exemplo, onde os pontos azuis representam os cinco vizinhos mais próximos ($k=5$) e os pontos vermelhos são aqueles adicionados à visualização com o acréscimo de 100% sobre o número de elementos retornados.




Figura 4.25 – Visualização de 5-NN com acréscimo de 100% sobre o número de elementos retornados: região densa.

Nas consultas usando dimensão fractal, o valor informado para k influencia diretamente no cálculo do raio que delimita a região de interesse.

Assim, a visualização de uma consulta aos cinco vizinhos mais próximos de um dado centro de busca com acréscimo de 100% sobre o número de elementos retornados, utilizando-se raio estimado pela dimensão fractal, tende a exibir mais elementos por estar em uma região densa.

Este caso é ilustrado na Figura 4.26, onde juntamente com os cinco vizinhos mais próximos (pontos azuis) foram exibidos os elementos que se encontram dentro da região delimitada pelo raio estimado que considerou o acréscimo do valor de k .




Figura 4.26 – Visualização de 5-NN com acréscimo de 100% sobre o número de elementos retornados usando dimensão fractal: região densa.

Nota-se que elementos e/ou agrupamentos próximos são visualizados, permitindo que o usuário faça sua interpretação sobre um conjunto maior, podendo decidir sobre a importância destes elementos para a sua pesquisa.

De outro modo, em regiões onde a distribuição dos elementos é esparsa, considerar um valor maior de k com uso da dimensão fractal, pode oferecer resultado diferente, fazendo com que um conjunto menor de elementos seja visualizado.

Considere a mesma consulta aos cinco vizinhos mais próximos com acréscimo de 100% sobre o número de elementos retornados e sem uso da dimensão fractal. Por se tratar de uma região esparsa, elementos de agrupamentos distintos são retornados.

Na ilustração feita na Figura 4.27, os pontos vermelhos representam os elementos acrescentados ao valor de $k=5$. Nota-se a presença de elementos de outros agrupamentos que, para o usuário, podem não ser relevantes.




Figura 4.27 – Visualização de 5-NN com acréscimo de 100% sobre o número de elementos retornados: região esparsa.

Ao se considerar consultas com uso da dimensão fractal em regiões esparsas, o acréscimo sobre o número de elementos retornados pode descartar elementos que se posicionam mais distantes, o que pode indicar se tratar de elementos não relevantes para o contexto estudado.

Suponha a mesma consulta aos cinco vizinhos mais próximos, com uso da dimensão fractal, executada em uma região esparsa e com aumento de 100% sobre o número de elementos no retorno. Apesar de ser considerado um valor maior de k , por se tratar de uma região esparsa e da região de interesse ter sido delimitada pelo raio estimado pela dimensão fractal, apenas 6 elementos são visualizados. Este exemplo pode ser visto na Figura 4.28.




Figura 4.28 – Visualização de 5-NN com acréscimo de 100% sobre o número de elementos retornados usando dimensão fractal: região esparsa.

4.4.4 Estimativa do raio da consulta com acréscimo % de k para cálculo do raio

Considerou-se o uso da dimensão fractal para delimitar a região de interesse de uma consulta onde a imagem do tempo $t=15$ da classe 431 foi usada como centro de busca para encontrar os cinco vizinhos mais próximos (5-NN). Foi acrescentado 60% ao valor de k para a realização do cálculo do raio que delimitou a região de interesse.

Embora 60% sobre o valor de k seja igual a oito (5-NN acrescido de 60%), por fazer uso do raio estimado, nesta consulta foram visualizados nove elementos. Eles são os elementos que representam as imagens dos tempos 10, 5, 0, 20, 25 e 30 da classe 431 e as imagens dos tempos 15, 25 e 35 da classe 432. Este resultado pode ser visto na Figura 4.29, onde foram exibidas junto das esferas vermelhas, as imagens que os elementos adicionados à região de interesse representam.

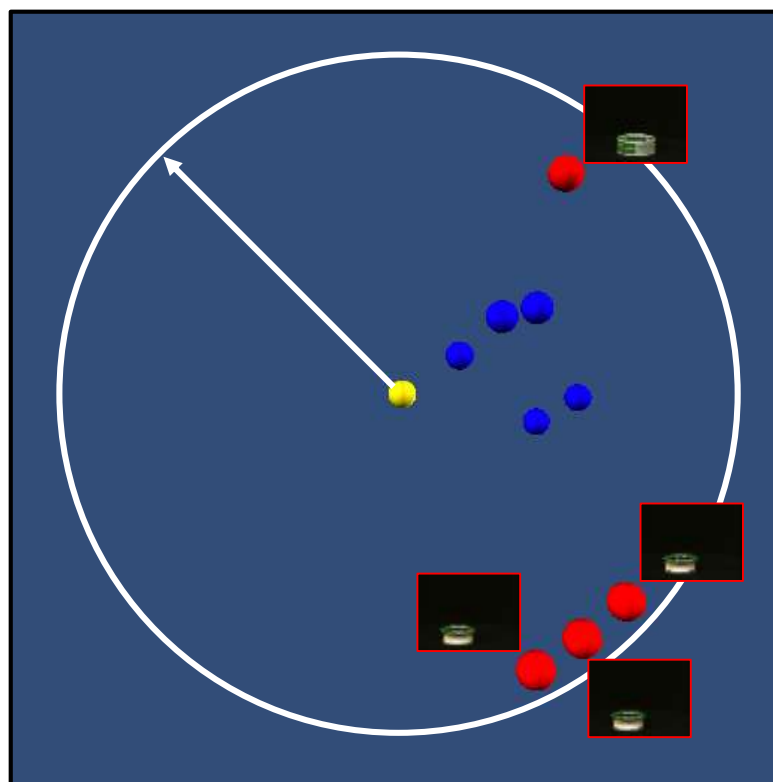


Figura 4.29 – Visualização de consulta com acréscimo de % k para cálculo do raio.

Na visualização é possível identificar os cinco vizinhos mais próximos representado por esferas azuis e os elementos que foram acrescentados à região de interesse representados por esferas vermelhas.

É possível perceber que um dos elementos acrescentados à visualização (esfera vermelha na parte superior) pertence ao mesmo agrupamento da imagem usada como centro de busca e que os elementos representados pelas esferas vermelhas da parte inferior, pertencem a um agrupamento diferente daquele formado pelos cinco vizinhos mais próximos.

O conjunto de imagens visualizadas nesta consulta é exibido na Figura 4.30.




Figura 4.30 – Imagens visualizadas em consulta com acréscimo de % k para cálculo do raio. Em (a) a imagem usada como centro de busca. Em (b) o conjunto visualizado.

4.4.5 Estimando o raio da consulta com acréscimo de % do raio estimado

Um novo cenário permitiu realizar uma consulta usando-se o valor da dimensão fractal e a imagem no tempo $t=30$ da classe 85 como centro de busca para encontrar os seus 3 vizinhos mais próximos. Nesta consulta, o raio que delimitou a região de interesse foi incrementado em 100% do seu valor, gerando uma nova região de interesse.

A visualização desta consulta é exibida na Figura 4.31, onde $r1$ representa o valor inicial do raio estimado e $r2$ mostra o seu novo valor após o incremento de 100%. Nota-se que, ao aumentar o raio da consulta em 100%, os demais elementos da classe foram adicionados à visualização, representados por esferas vermelhas.

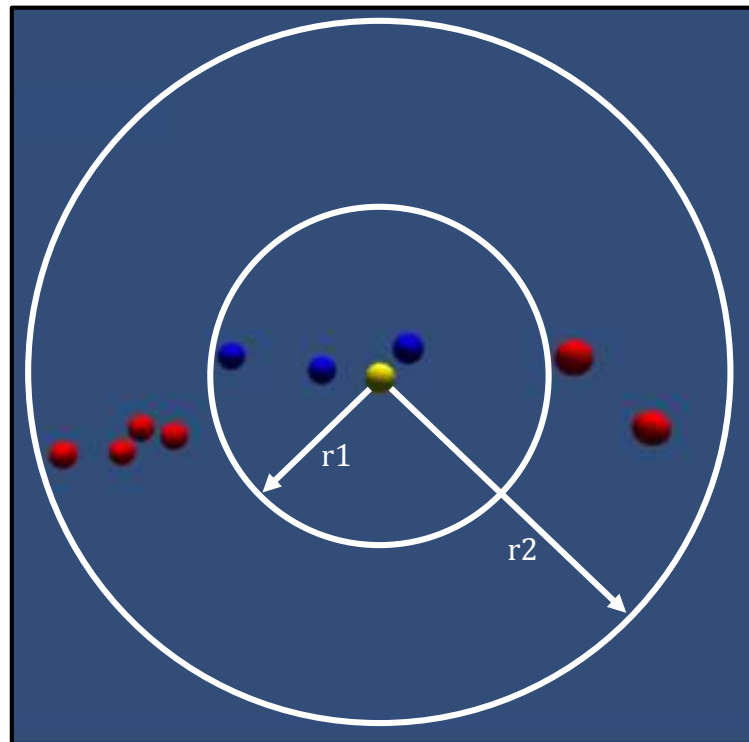


Figura 4.31 – Alteração da região de interesse com aumento em percentual do raio estimado.

As imagens visualizadas são as imagens dos tempos 35, 25, 20, 40, 15, 45, 10, 5 e 0 da classe 85, exibidas na Figura 4.32.

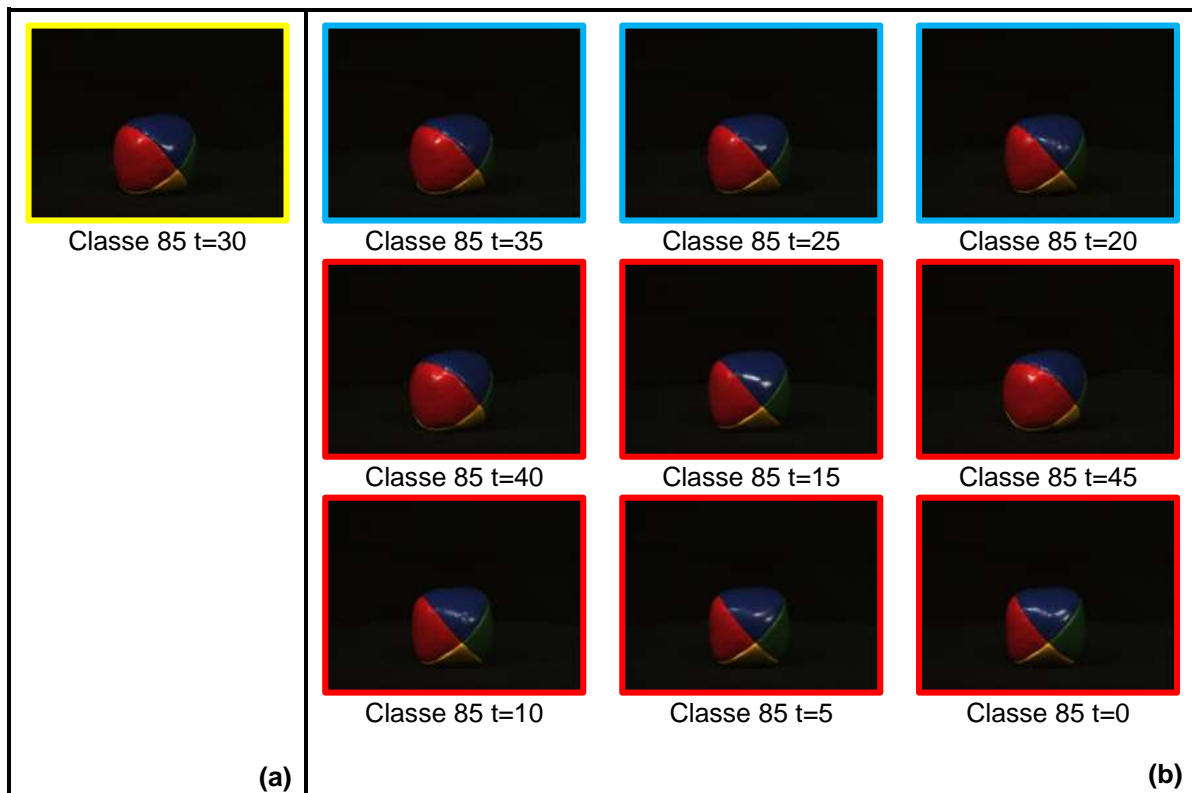


Figura 4.32 – Imagens visualizadas em consulta com alteração do raio estimado.

Visualmente é possível perceber que o incremento de 100% sobre o valor do raio estimado, permitiu que fossem acrescentados seis novos elementos e que todos eles pertencem à mesma classe daquele usado como centro de busca. Tais elementos podem ser analisados como relevantes para a consulta, bem como podem ser descartados, quando não representarem imagens que o usuário considere importantes.

4.5 Considerações finais

A representação visual de pequenas áreas do conjunto de dados permitiu obter melhor mapeamento dos elementos no espaço tridimensional, visto que menor quantidade de dados gera menor erro no mapeamento.

Novos conhecimentos a respeito dos dados puderam ser descobertos ao visualizá-los e interagir com os mesmos, favorecendo a criação de hipóteses ou formulação de análises reais sobre os dados, uma vez que a visualização pode favorecer o entendimento das pessoas.

Ao visualizar apenas uma região de interesse do conjunto de dados, obteve-se facilidades na interpretação e melhores condições de fazer análises pois, uma menor quantidade de elementos exibida na tela, também facilita o entendimento por parte do usuário.

Capítulo 5

VISUALIZAÇÃO DE ESTIMATIVAS DE TRAJETÓRIAS MÉTRICOS-TEMPORAIS

Este capítulo apresenta cenários de visualização das consultas com estimativa de trajetória métrico-temporal. Diferentes quantidades de elementos foram usadas para realizar as estimativas e diversas maneiras de definir a região de interesse consultada estão descritas.

5.1 Considerações iniciais

O sistema de visualização desenvolvido permitiu explorar as consultas com estimativas de trajetórias métrico-temporais propostas por (BUENO, 2009) e (SOUSA; BUENO, 2014). Em seus trabalhos, os autores fizeram um estudo da evolução dos dados com o passar do tempo, onde uma trajetória de dados foi feita a partir da análise de elementos tidos como referência, apresentando seus resultados em espaços multidimensionais.

Um exemplo de dados métricos-temporais pode ser entendido da necessidade de acompanhar o diagnóstico de um paciente com imagens de seus exames realizados. Imagens de tomografias feitas em momentos diferentes de tratamento (por exemplo, instantes $t=2$ meses e $t=6$ meses), podem ser usadas para estimar a evolução dos dados, criando-se uma estimativa que possibilite recuperar uma imagem similar ao que seria uma imagem deste paciente doze meses após o início do seu tratamento.

Como não é possível recriar uma imagem no instante $t=12$ meses a partir da estimativa de sua posição no espaço mapeado, realiza-se uma busca aos vizinhos mais próximos usando a posição estimada como centro da consulta para encontrar imagens semelhantes e que possam indicar uma situação provável do paciente neste momento. A figura 5.1 ilustra este exemplo.




Figura 5.1 – Exemplo de evolução de dados ao longo do tempo (Adaptado de Sousa e Bueno, 2014).

Embora as imagens recuperadas nesta consulta por similaridade aos vizinhos mais próximos obedeam aos critérios de busca, alguns elementos podem estar distantes do centro da consulta o suficiente para não serem interessantes. Assim, ao visualizar a resposta da consulta, o usuário pode fazer uma melhor interpretação dos resultados e, provavelmente, considerar apenas imagens próximas como sendo relevantes, descartando as demais.

Este exemplo está demonstrado na Figura 5.2, onde as imagens nos tempos $t=2$ e $t=6$ foram usadas como elementos de referência para estimar um centro de busca no tempo $t=12$ e consultar os quatro vizinhos mais próximos desta estimativa. Neste cenário, apenas a imagem mais próxima da estimativa deve ser considerada como resultado relevante para a consulta e as demais imagens devem ser descartadas após a análise visual feita pelo usuário, por estarem distantes do centro de busca estimado para o tempo $t=12$.




Figura 5.2 – Análise visual dos 4 vizinhos mais próximos em uma consulta (Adaptado de Sousa e Bueno, 2014).

A proposta de (BUENO, 2009) apresenta uma forma de mapeamento dos dados de um espaço métrico para um espaço multidimensional, com dimensionalidade estimada pela dimensão fractal do conjunto para, então, nesse espaço mapeado realizar a estimativa das trajetórias.

No presente trabalho as estimativas de trajetórias foram criadas usando-se os próprios vetores de características dos elementos indicados como referência.

Embora o protótipo implementado esteja limitado a trabalhar com dados multidimensionais, uma vez que usa vetores de características das imagens para realizar as estimativas, não há impedimento de adaptação para processamento de dados representados em espaços métricos. Para isto, faz-se necessário processar previamente o conjunto de dados métricos a fim de mapeá-los para um espaço multidimensional, onde será possível usar os vetores de características para consultar e visualizar os resultados.

Dados de alta dimensionalidade também poderiam ser mapeados pelo protótipo com a realização de uma etapa intermediária de redução de dimensionalidade, mediante adaptação para esta finalidade.

O protótipo permite que o usuário selecione diferentes quantidades de elementos para fazer sua estimativa. Nestes casos, os vetores de características de cada elemento são combinados por meio da interpolação dos seus valores pela

aplicação do método proposto por Lagrange (HUMES et al., 1984). Tal método é oferecido na biblioteca de código livre Java chamada *Commons Math*⁵.

Nos cenários testados, tomou-se os vetores de características das imagens usadas como parâmetros de entrada neste processo a fim de gerar um novo vetor que representasse a estimativa. Assim, foi possível usar este novo vetor para realizar a consulta.

Foram feitas estimativas em instantes passados, futuros e intermediários e as regiões de interesse foram definidas por um valor fixo de k ou pelo uso da dimensão fractal (raio estimado), com possibilidade de alteração por meio do acréscimo de um valor percentual para ambos os casos (conforme apresentado nas seções 4.3.1, 4.3.2 e 4.4.3).

Os mesmos recursos usados para delimitar a região de interesse estimada foram usados nas regiões dos elementos de referência, uma vez que, conhecer as regiões próximas a estes elementos pode ser interessante para o usuário.

Na seção 5.2 é apresentada uma consulta de estimativa métrico-temporal com determinação da região de interesse pelo valor indicado em uma consulta k-NN. Na seção 5.3 é discutido como a região de interesse pode ser alterada a partir de acréscimo sobre o valor k de elementos. A dimensão fractal foi usada na seção 5.4 para delimitar a área a ser visualizadas nas consultas e a seção 5.5 relata como esta área pode ser expandida com acréscimo de % do raio estimado.

5.2 Estimativa de trajetória métrico-temporal em consulta k-NN

Ao visualizar os dados em um espaço tridimensional e analisar somente os elementos da região de interesse de forma visual, uma melhor análise pode ser feita, permitindo encontrar dados que podem ser considerados como de real importância e também descartar dados visualizados mas que não auxiliam no objetivo da consulta.

Um cenário permitiu visualizar os dados recuperados em uma consulta com estimativa da trajetória métrico-temporal, cujo objetivo foi encontrar os 10 vizinhos mais próximos do tempo estimado $t=15$ usando os elementos nos tempos $t=0$, $t=5$,

⁵ <http://commons.apache.org/proper/commons-math/index.html>

$t=10$, $t=20$ e $t=25$ da classe 55 como elementos de referência. Neste cenário, a região de interesse foi determinada pelos k elementos da consulta ao tempo estimado e o seu resultado está exibido na Figura 5.3, onde foram destacados os tempos dos elementos de referência e tempo estimado $t=15$.

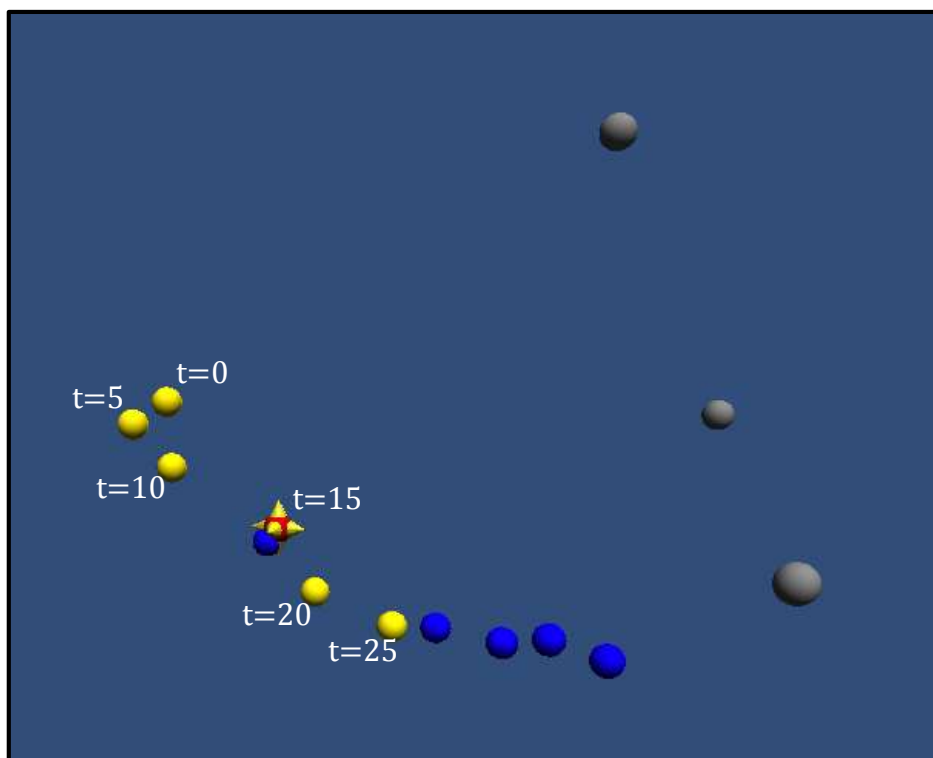


Figura 5.3 – Visualização de consulta com estimativa de trajetória métrico-temporal.

Esta consulta recuperou dez imagens dos tempos 15, 20, 10, 25, 0, 30, 5, 35, 40 e 45 da classe 55.

Na visualização, as esferas amarelas representam os elementos usados para criar a estimativa da trajetória e que, neste caso, também fazem parte da resposta da consulta. As esferas azuis completam o conjunto dos 10 vizinhos mais próximos do tempo estimado.

Nas consultas com estimativa, novas figuras foram incorporadas à visualização: uma estrela vermelha para representar o elemento no tempo estimado e esferas de cor cinza para representar elementos que não fazem parte da resposta da consulta, porém, representam elementos próximos daqueles usados como referências para a estimativa.

Nota-se que o elemento que representa o tempo estimado $t=15$ faz parte do conjunto resultado da consulta e o elemento que representa a estimativa (estrela vermelha) encontra-se muito próximo dele.

As imagens retornadas nesta consulta são exibidas na Figura 5.4.

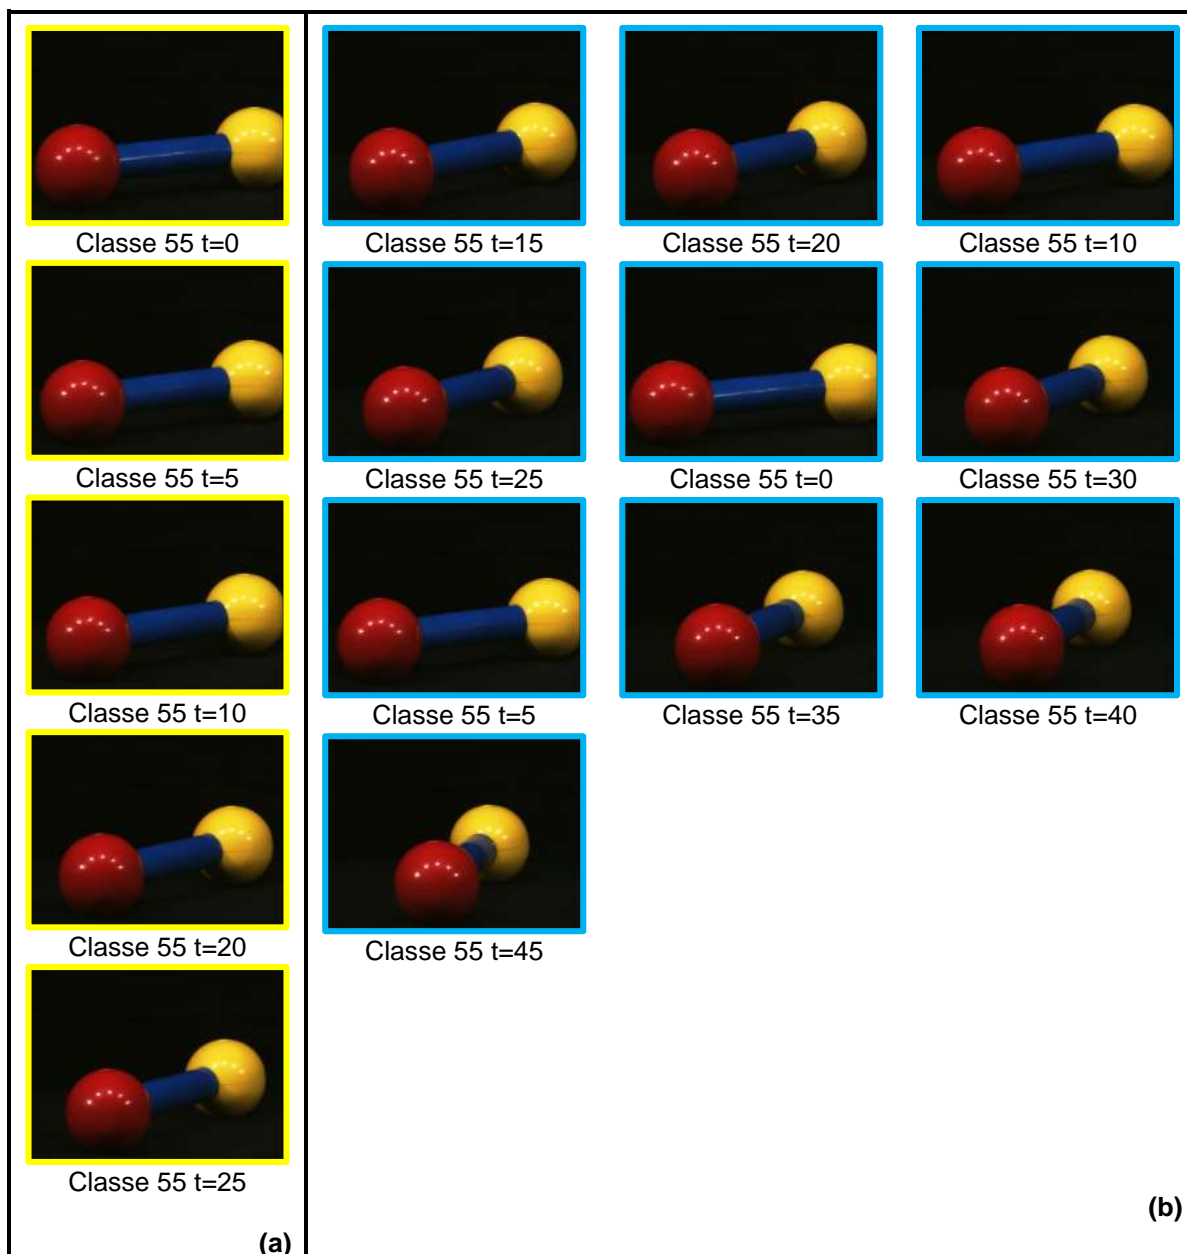


Figura 5.4 – Imagens recuperadas em consulta com estimativa de trajetória métrico-temporal. Em (a) as imagens usadas para estimar. Em (b) as imagens do conjunto resposta da consulta.

5.3 Expansão da região de interesse com % de k elementos

A fim de mostrar a região da consulta, e não somente os k -vizinhos mais próximos, uma nova consulta com estimativa de trajetória métrico-temporal foi feita, cuja região de interesse foi definida acrescentando-se 80% ao valor inicial de k , para $k=5$.

As imagens dos tempos $t=10$ e $t=15$ da classe 256 foram usados para estimar uma consulta no tempo $t=20$. Ao visualizar a região determinada, o usuário pode analisar se os elementos representados são relevantes para a consulta ou não. Este cenário está exibido na Figura 5.5, onde os elementos usados para estimar tiveram seus tempos destacados, assim como o tempo estimado $t=20$.




Figura 5.5 – Visualização de consulta com estimativa de trajetória métrico-temporal com alteração da região de interesse por acréscimo do k .

A região de interesse delimitada pelo acréscimo do percentual sobre o número de elementos da consulta foi composta por nove elementos (5-NN acrescido de 80%). Eles representam as imagens dos tempos 20, 15, 10, 0, 5, 25, 35 e 30, pertencentes à classe 256 e a imagem do tempo 45 da classe 824.

As esferas azuis e amarelas representam os cinco vizinhos mais próximos do tempo estimado $t=20$, sendo que as esferas amarelas também representam os elementos usados como referência para a estimativa. As esferas vermelhas representam as imagens acrescentadas pelo percentual sobre o valor inicial de k informado.

É possível perceber que a imagem do tempo $t=20$ faz parte do conjunto resposta desta consulta com estimativa da trajetória métrico-temporal e a estrela vermelha que representa o elemento no tempo estimado $t=20$, posicionou-se próxima desta imagem. A esfera de cor cinza, embora presente na visualização, não compõe o conjunto resultado da consulta.

As imagens que formam a região da consulta são exibidas na Figura 5.6.

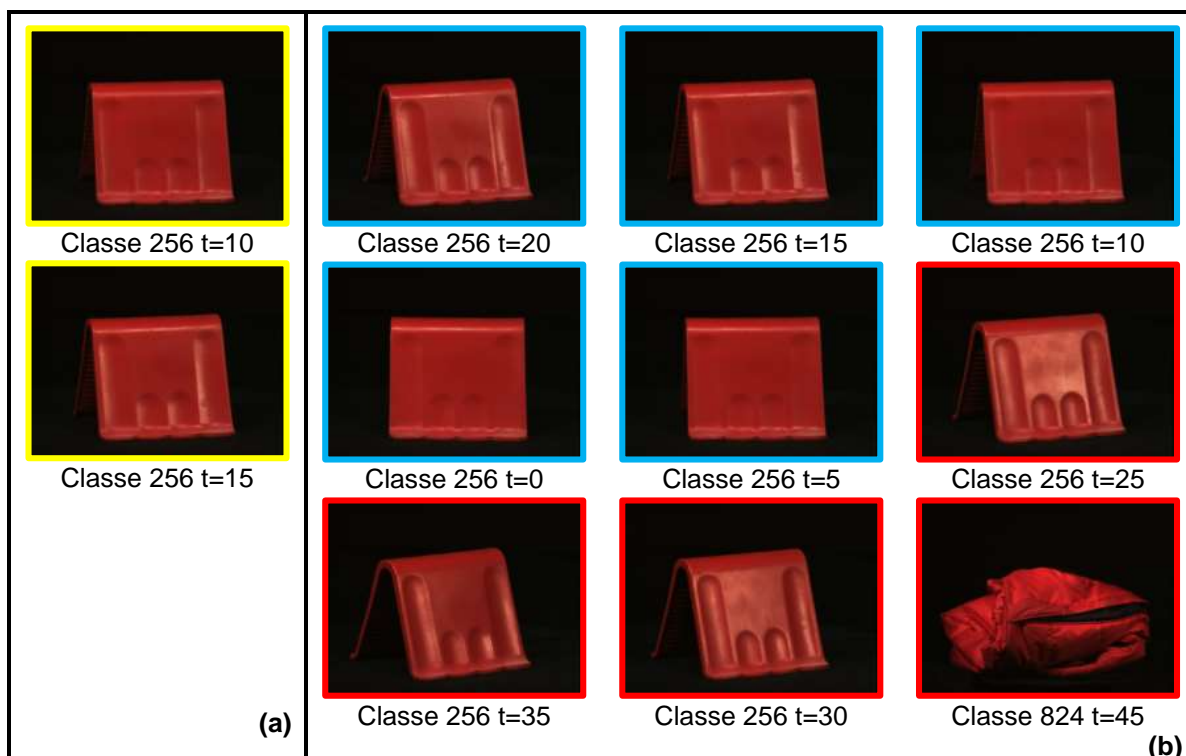


Figura 5.6 – Imagens visualizadas em consulta com estimativa de trajetória métrico-temporal. Em (a) as imagens usadas para estimar. Em (b) as imagens da região de interesse.

5.4 Delimitação da região de interesse pela dimensão fractal

A delimitação da região de interesse pela dimensão fractal também foi possível nas consultas de trajetória métrico-temporal. Assim como nos outros cenários descritos, o raio estimado permitiu alterar a área a ser visualizada e exibir um número diferente de elementos daquele informado para k , uma vez que estas consultas

consideram a densidade de elementos na região consultada e podem exibir mais ou menos do que k elementos na visualização.

Para analisar tal situação, foi realizada uma consulta com estimativa de trajetória métrico-temporal cuja região de interesse foi determinada pelo raio estimado a partir da dimensão fractal. Buscou-se encontrar os cinco vizinhos mais próximos (5-NN) do tempo estimado $t=10$ usando-se as imagens dos tempos $t=0$ e $t=5$ da classe 148 como elementos de referência.

Nesta consulta, apesar de ter sido indicado inicialmente o valor de $k=5$, o raio estimado expandiu a área de visualização e mostrou 10 elementos: aqueles que representam as imagens dos tempos 10, 5, 0, 15, 40, 20, 30, 35, 45 e 25 da classe 148. A Figura 5.7 ilustra este cenário.




Figura 5.7 – Consulta com estimativa de trajetória métrico-temporal com alteração da região de interesse pela dimensão fractal.

Na visualização, as esferas azuis e amarelas (elementos de referência) representam os cinco elementos da consulta que foram determinados pelo k (5-NN).

As cinco esferas vermelhas representam os elementos acrescentados à visualização por estarem posicionadas dentro do raio estimado a partir da dimensão fractal.

Nota-se que o elemento que representa a imagem do tempo $t=10$ pertence ao conjunto resposta e encontra-se próximo da estrela vermelha que representa o tempo estimado. É possível perceber também que as imagens visualizadas pertencem à mesma classe daqueles elementos usados para fazer a estimativa. Tais imagens são exibidas na Figura 5.8.

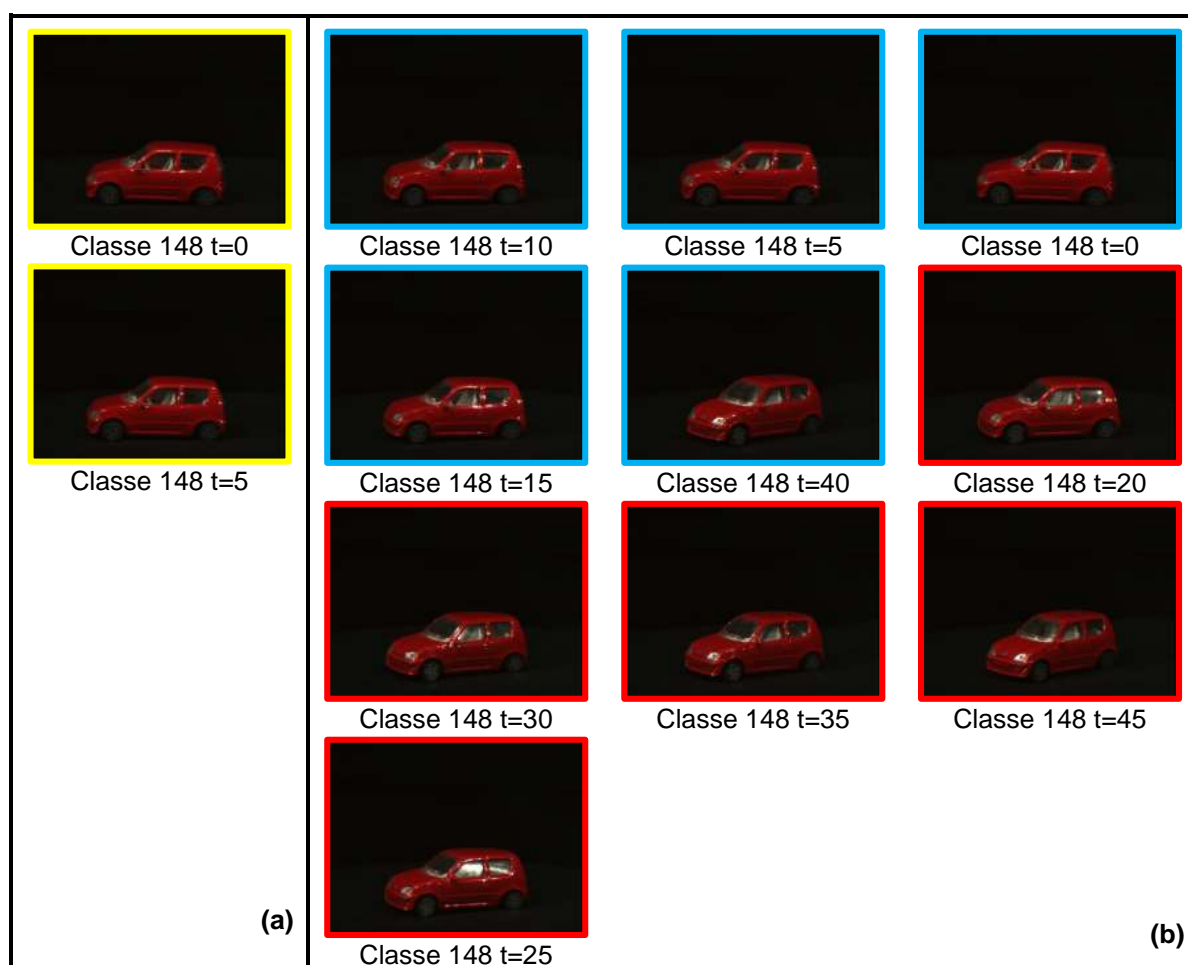


Figura 5.8 – Imagens visualizadas em consulta com estimativa de trajetória métrico-temporal. Em (a) as imagens usadas para estimar. Em (b) as imagens da região de interesse.

Ao analisar e interagir com o resultado, fica a critério do usuário decidir se os elementos adicionados, por pertencerem à região de interesse, devem ser considerados como importantes ou não para o objetivo da consulta.

5.5 Alteração da região de interesse com acréscimo de % do raio estimado

É possível que o raio estimado usado para delimitar a região de interesse faça com que uma consulta recupere uma quantidade menor de elementos do que o valor inicial indicado para k .

Em um novo cenário, uma consulta com estimativa de trajetória métrico-temporal usou três elementos de referência para criar a trajetória ao tempo estimado $t=30$. Utilizou-se os elementos que representam os tempos $t=15$, $t=20$ e $t=25$ da classe 824 para encontrar os cinco vizinhos mais próximos do tempo estimado.

Em uma primeira execução desta consulta não foi usada a dimensão fractal para delimitar a região de interesse, o que fez com que a resposta fosse composta pelo valor fixo indicado para k , ou seja, cinco elementos. A Figura 5.9 ilustra este cenário.




Figura 5.9 – Consulta com estimativa de trajetória métrico-temporal.

Na visualização, as duas esferas azuis e as três esferas amarelas (elementos de referência) formam a resposta da consulta e são os elementos que representam as imagens dos tempos 30, 25, 35, 20 e 15 da classe 824. As esferas de cor cinza, embora apareçam na visualização, não compõem o resultado da consulta.

Nota-se que a imagem do tempo $t=30$ está presente na resposta da consulta, posicionada próxima da estrela que representa o tempo estimado e que os elementos usados para estimar também pertencem ao conjunto resultado. Estas imagens são exibidas na Figura 5.10.




Figura 5.10 – Imagens recuperadas em consulta com estimativa de trajetória métrico-temporal. Em (a) as imagens usadas para estimar. Em (b) as imagens da região de interesse.

Considerou-se a mesma consulta aos cinco vizinhos mais próximos, porém desta vez, com a região de interesse delimitada pela dimensão fractal. Apenas o elemento que representa a imagem do tempo 30 da classe 824 foi obtido como resposta. Este é o único elemento que se encontra dentro da região delimitada pelo raio estimado para uma consulta 5NN, o que fez com que, nesta execução, menos do que k elementos fossem visualizados.

A fim de alterar este cenário e expandir a área a ser visualizada, realizou-se novamente a mesma consulta aos cinco vizinhos mais próximos, porém com a região de interesse delimitada pelo raio estimado pela dimensão fractal do conjunto de dados acrescentado em 200% do seu valor. O resultado pode ser visualizado na Figura 5.11.




Figura 5.11 – Consulta com estimativa de trajetória métrico-temporal com alteração da região de interesse pela dimensão fractal com aumento em percentual do raio estimado.

Foram visualizados sete elementos da classe 824 e são os que representam as imagens dos tempos 30, 25, 35, 20, 15, 40 e 10.

As esferas azuis e amarelas representam os cinco vizinhos mais próximos do tempo estimado $t=30$ e as esferas vermelhas representam vizinhos adicionados à visualização por se encontrarem dentro do raio estimado. As esferas de cor cinza, embora apareçam na visualização, não compõem a região de interesse delimitada para esta consulta.

Observou-se que a imagem do tempo $t=30$ está presente no resultado próxima da estrela que representa o tempo estimado. As imagens visualizadas estão exibidas na Figura 5.12.




Figura 5.12 – Imagens recuperadas em consulta com estimativa de trajetória métrico-temporal. Em (a) as imagens usadas para estimar. Em (b) as imagens da região de interesse.

5.6 Considerações finais

Nas visualizações das consultas com estimativas de trajetórias métrico-temporais (BUENO, 2009) foi possível entender, em um espaço 3D, como é o arranjo das imagens mais próximas de instantes temporais passado, intermediário ou futuro. Os cenários descritos apresentaram diferentes formas de delimitação da região de interesse, mantendo a preocupação de gerar um melhor mapeamento da área a ser visualizada, tendo em vista a importância da análise visual também neste tipo de consulta.

Foi possível conhecer e entender a evolução temporal com base em diferentes quantidades de elementos tidos como referência para a estimativa da trajetória e as muitas formas de determinar a região de interesse das consultas permitiram entender como é a distribuição dos dados em pequenas regiões, bem como em comparação com o conjunto todo. Isto permitiu encontrar, visualmente, dados de real importância para os problemas estudados ou descartar dados irrelevantes.

Capítulo 6

CONSIDERAÇÕES FINAIS

Neste capítulo são retratadas as conclusões deste trabalho de mestrado e são destacadas as principais contribuições dos estudos realizados sobre visualização em consultas por similaridade limitando-se a apenas uma região do conjunto de dados. Em seguida são relatados possíveis trabalhos futuros.

O principal objetivo deste trabalho foi usar uma estratégia de visualização de consultas por similaridade que permitisse ao usuário analisar visualmente apenas regiões específicas de um conjunto de dados.

Para isto, formas de delimitação de tal região de interesse das consultas foram implementadas e, ao limitar os dados a serem visualizados a conjuntos menores, foi possível fazer o uso de um método de mapeamento capaz de manter a distribuição dos dados no espaço mapeado mais próxima da distribuição real.

Ao restringir o número de elementos a um conjunto menor, o mapeamento destes dados para uma dimensão 3D, feito pelo algoritmo MDS, gera menos distorção na representação da relação de distância entre os dados, o que permite gerar visualizações que representem mais fielmente a realidade estudada.

A princípio, o número k de elementos de uma consulta k -NN foi usado para delimitar a área a ser mapeada e visualizada. Trabalhar com um número fixo de elementos na consulta dispensa o mapeamento do conjunto por completo, já que envolve apenas uma pequena região demarcada.

Foi possível realizar a expansão da região de interesse da consulta com o propósito de obter um número maior de elementos, uma vez que pode ser interessante conhecer como é o relacionamento entre os elementos da resposta da consulta e aqueles que estão nas suas proximidades. Para isto, foi acrescentado um percentual sobre o valor de k e obter um número maior de dados para o mapeamento, porém

este tipo de parâmetro considera ainda uma área visualizada composta por um número fixo de elementos.

Como alternativa à esta delimitação da região por número fixo, outra maneira de expansão da região de visualização foi implementada. Um percentual de acréscimo foi aplicado sobre a distância do elemento mais afastado do centro de busca em uma consulta k-NN para calcular um raio que delineou a nova região de interesse. Neste caso, a consulta realizada foi transformada em uma consulta por abrangência e foram visualizados todos os elementos que se encontraram dentro do raio estimado. Isto permitiu visualizar áreas com números flexíveis de elementos, pois levou em consideração a distribuição dos dados na região pesquisa.

A dimensão fractal também viabilizou a delimitação da região de interesse das consultas. Ela considera a distribuição média dos elementos do conjunto de dados e não somente a distribuição local. Seu valor foi usado para encontrar um raio estimado para selecionar os elementos dentro deste raio.

Novamente houve a conversão em uma consulta por abrangência e a quantidade de elementos visualizados foi maior ou menor do que a quantidade informada inicialmente, de acordo com a densidade da distribuição dos elementos em cada região pesquisada e a distribuição geral do conjunto como um todo.

Consultas realizadas usando raio estimado pela dimensão fractal em regiões com distribuição densa de elementos tendem a recuperar mais elementos do que o valor indicado para k , em contrapartida, regiões de distribuição esparsa tendem a não mostrar nos resultados os elementos mais distantes do centro de busca.

Neste trabalho, o valor do raio estimado pela dimensão fractal pode ser acrescentado em percentual, assim como o valor de k indicado na consulta e que é usado para calcular tal raio. O uso do raio estimado também converte as consultas aos vizinhos mais próximos em consultas por abrangência.

Também foi possível explorar as consultas com estimativa de trajetória métrico-temporais ao consultar dados de regiões estimadas em tempos passados, futuros e/ou intermediários daqueles dados usados para estimar. O protótipo implementado permitiu que um número variado de elementos fosse indicado como referência para criar as estimativas de trajetórias e neste tipo de consulta também foi permitida a demarcação da região de interesse com os mesmos parâmetros citados anteriormente.

Em todos os cenários testados, os dados selecionados foram representados em um ambiente tridimensional onde foram possíveis a observação e a interação com os mesmos. Esta análise visual tem o propósito de melhorar o entendimento sobre os dados ao usar os benefícios garantidos pela percepção humana com o intuito de auxiliar na diminuição do *gap* semântico.

6.1 Principais contribuições

As alternativas de delimitação da região de interesse das consultas apresentadas neste trabalho permitiram explorar visualmente regiões do conjunto de dados que foram definidas por:

- Consultas aos k-vizinhos mais próximos com expansão da área a ser visualizada com acréscimo percentual sobre o número de elementos da consulta ou sobre o raio do k-NN.
- Uso da dimensão fractal do conjunto: nestes casos a consulta converte-se em consulta por abrangência e recupera os elementos que se encontram dentro do raio estimado. Foi possível expandir a área da consulta por aplicação de acréscimo sobre o número de elementos usados para calcular o raio ou por acréscimo percentual sobre o próprio raio estimado.
- Estimativas de trajetórias métrico-temporais com quantidade de elementos também definida pelos mesmos métodos das consultas anteriores.

6.2 Trabalhos futuros

Algumas situações que podem ser abordadas como propostas de trabalhos futuros para continuação deste estudo são:

- Analisar outras técnicas de redução de dimensionalidade que permitam mapear os dados das regiões de interesse para uma espaço tridimensional,

a fim de manter a melhor distribuição dos dados possível, como a técnica t-SNE, proposta em (MAATEN; HINTON, 2008).

- Pesquisar e testar outros métodos capazes de fazer a interpolação/extrapolação dos valores dos atributos dos vetores de características nas consultas com estimativa de trajetórias métrico-temporais.

REFERÊNCIAS

AJEESH, S. S.; INDU, M. S. FEATURE EXTRACTION TECHNIQUES ON CBIR-A REVIEW. **International Journal of Computer Engineering and Technology**, v. 4, n. 4, p. 467–474, 2013.

ANKERST, M. Visual data mining with pixel-oriented visualization techniques. **Proceedings of the ACM SIGKDD Workshop on Visual Data Mining**, 2001.

ARANTES, A. S. et al. The Fractal Dimension Making Similarity Queries More Efficient. **Second Workshop on Fractals and Self-similarity in Data Mining: Issues and Approaches (in conjunction with 9th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining)**, p. 12–17, 2003.

AREVALILLO-HERRÁEZ, M.; DOMINGO, J.; FERRI, F. J. Combining similarity measures in content-based image retrieval. **Pattern Recognition Letters**, v. 29, n. 16, p. 2174–2181, dez. 2008.

ASARNOW, D. **Mdscale : A free and open-source Multidimensional Scaling (MDS) library for Java**, 2011. Disponível em: <<https://github.com/asarnow/mdscale>>

ASLANDOGAN, Y. A.; YU, C. T. Techniques and systems for image and video retrieval. **IEEE Transactions on Knowledge and Data Engineering**, v. 11, n. 1, p. 56–63, 1999.

BARIONI, M. C. N. et al. Data Visualization in RDBMS. **Information Systems and Databases (ISDB 2002), Proceedings of the IASTED International Conference, September 25-27, 2002, Tokyo, Japan**, p. 264–269, 2002.

BARROSO, R.; BUENO, R. Método de Balanceamento de Múltiplos Descritores Usando Condições de Contorno para Pesquisas por Similaridade. **Simpósio Brasileiro de Bancos de Dados - SBBD**, p. 49–54, 2013.

BERBAR, M. A. Three robust features extraction approaches for facial gender classification. **The Visual Computer**, v. 30, n. 1, p. 19–31, 26 jan. 2014.

BERCHTOLD, S.; BOHM, C.; KRIEGEL, H.-P. **The pyramid-tree: Breaking the**

curse of dimensionality. Proceeding SIGMOD '98 Proceedings of the ACM SIGMOD international conference on Management of data. **Anais...1998**

BIEDERMAN, I. Recognition-by-Components: A Theory of Human Image Understanding. **Psychological Review**, v. 94, n. 2, p. 115–147, 1987.

BÖHM, C.; BERCHTOLD, S.; KEIM, D. A. Searching in high-dimensional spaces: Index structures for improving the performance of multimedia databases. **ACM Computing Surveys**, v. 33, n. 3, p. 322–373, 1 set. 2001.

BRAUNMULLER, B. et al. **Efficiently supporting multiple similarity queries for mining in metric databases**. Proceedings of 16th International Conference on Data Engineering (Cat. No.00CB37073). **Anais...IEEE Comput. Soc**, 2000

BRIN, S. Near Neighbor Search in Large Metric Spaces. **Proceedings of the 21st VLDB Conference. Zurich, Switzerland**, p. 574–584, 1995.

BUENO, R. **Tratamento de tempo e dinamicidade em dados representados em espaços métricos**. São Carlos: Universidade de São Paulo, 15 dez. 2009.

CARDOSO, A. C. **INCLUSÃO DE DIVERSIDADE EM CONSULTAS AOS VIZINHOS MAIS PRÓXIMOS USANDO DESCRITORES DISTINTOS PARA SIMILARIDADE E DIVERSIDADE**. [s.l.] UFSCar (Dissertação de mestrado), 2017.

CARÉLO, C. C. M. et al. Slicing the metric space to provide quick indexing of complex data in the main memory. **Information Systems**, v. 36, n. 1, p. 79–98, 2011.

CHÁVEZ, E. et al. Searching in metric spaces. **ACM Computing Surveys**, v. 33, n. 3, p. 273–321, 1 set. 2001.

CHINO, F. J. T. et al. **MAMView: A Visual Tool for Exploring and Understanding Metric Access Methods**. Proceedings of the 2005 ACM symposium on Applied computing - SAC '05. **Anais...New York, New York, USA: ACM Press**, 2005

CIACCIA, P.; PATELLA, M.; ZEZULA, P. M-tree: An Efficient Access Method for Similarity Search in Metric Spaces. **23rd VLDB Conference**, p. 426–435, 1997.

DATTA, R. et al. Image retrieval. **ACM Computing Surveys**, v. 40, n. 2, p. 1–60, 1 abr. 2008.

DEMNER-FUSHMAN, D. et al. Design and Development of a Multimodal Biomedical Information Retrieval System. **Journal of Computing Science and Engineering**, v. 6, n. 2, p. 168–177, 30 jun. 2012.

DENGSHENG ZHANG; GUOJUN LU. **Content-based shape retrieval using different shape descriptors: a comparative study**. IEEE International Conference on Multimedia and Expo, 2001. ICME 2001. **Anais...IEEE**, 2001

DIAS, R. L. et al. **Visual-Interactive k-NDN Method (VIK): A Novel Approach to Visualize and Interact with Content-Based Image Retrieval Systems Regarding Similarity and Diversity**. 2017 21st International Conference Information Visualisation (IV). **Anais...IEEE**, jul. 2017Disponível em: <<http://ieeexplore.ieee.org/document/8107950/>>

EAKINS, J. P. Towards intelligent image retrieval. **Pattern Recognition**, v. 35, n. 1, p. 3–14, jan. 2002.

ELMQVIST, N.; FEKETE, J.-D. Hierarchical Aggregation for Information Visualization: Overview, Techniques, and Design Guidelines. **IEEE Transactions on Visualization and Computer Graphics**, v. 16, n. 3, p. 439–454, maio 2010.

FADEL, S. G. et al. LoCH: A neighborhood-based multidimensional projection technique for high-dimensional sparse spaces. **Neurocomputing**, v. 150, n. PB, p. 546–556, fev. 2015.

FALOUTSOS, C.; KAMEL, I. Beyond R-trees Uniformity Using. **Proceedings of the thirteenth ACM SIGACTSIGMODSIGART symposium on Principles of database systems**, v. 8958546, p. 4–13, 1994.

FALOUTSOS, C.; LIN, K.-I. **FastMap: a fast algorithm for indexing, data-mining and visualization of traditional and multimedia datasets**. Proceedings of the 1995 ACM SIGMOD international conference on Management of data - SIGMOD '95. **Anais...New York, New York, USA: ACM Press**, 1995

FAYYAD, U. Mining databases: Towards algorithms for knowledge discovery. **Data Engineering Bulletin**, v. 21, n. 1, p. 39–48, 1998.

FODOR, I. K. **A Survey of Dimension Reduction Techniques**. Relatório Técnico UCRL-ID-148494, Center for Applied Scientific Computing, Lawrence Livermore National Laboratory, 2002: [s.n.].

FOGAÇA, I. C. O. D. S. **ANÁLISE DA EVOLUÇÃO TEMPORAL DE DADOS MÉTRICOS**. [s.l.] UFSCar (Dissertação de mestrado), 2016.

FREITAS, C. M. D. S. et al. Introdução à visualização de informações. **Revista Informática Teórica Aplicada**, v. VIII, p. 143–158, 2001.

GERSHON, N.; EICK, S. G.; CARD, S. K. Information visualization. **interactions**, v. 5, n. 2, p. 9–15, 1 mar. 1998.

GEUSEBROEK, J.-M.; BURGHOOTS, G. J.; SMEULDERS, A. W. M. The Amsterdam Library of Object Images. **International Journal of Computer Vision**, v. 61, n. 1, p. 103–112, jan. 2005.

GLUECK, M. et al. PhenoBlocks: Phenotype Comparison Visualizations. **IEEE Transactions on Visualization and Computer Graphics**, v. 22, n. 1, p. 101–110, 31 jan. 2016.

GRINSTEIN, G. G.; TRUTSCHL, M.; CVEK, U. **High-dimensional visualizations**. Proceedings of the Visual Data Mining Workshop, KDD. **Anais...**2001

HAUFF, C.; THOMEE, B.; TREVISIOL, M. Working notes for the placing task at MediaEval 2013. **CEUR Workshop Proceedings**, v. 1043, p. 1–2, 2013.

HECZKO, M. et al. Multiresolution similarity search in image databases. **Multimedia Systems**, v. 10, n. 1, p. 28–40, 1 jun. 2004.

HINNEBURG, A.; KEIM, D. A.; WAWRYNIUK, M. HD-Eye: visual mining of high-dimensional data. **IEEE Computer Graphics and Applications**, v. 19, n. 5, p. 22–31, 1999.

HJALTASON, G. R.; SAMET, H. Properties of embedding methods for similarity searching in metric spaces. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 25, n. 5, p. 530–549, maio 2003a.

HJALTASON, G. R.; SAMET, H. Index-driven similarity search in metric spaces. **ACM Transactions on Database Systems**, v. 28, n. 4, p. 517–580, 1 dez. 2003b.

HUANG, J. et al. Spatial Color Indexing and Applications. **International Journal of Computer Vision**, v. 35, n. 3, p. 245–268, 1999.

HUMES, A. F. P. C. et al. **Noções de Cálculo Numérico**. 1ª ed. São Paulo: McGraw-Hill, 1984.

INSELBERG, A.; DIMSDALE, B. Parallel Coordinates for Visualizing Multi-Dimensional Geometry. In: **Computer Graphics 1987**. Tokyo: Springer Japan, 1987. p. 25–44.

JOIA, P. et al. Local Affine Multidimensional Projection. **IEEE Transactions on Visualization and Computer Graphics**, v. 17, n. 12, p. 2563–2571, dez. 2011.

KANDOGAN, E. **Star coordinates: A multi-dimensional visualization technique with uniform treatment of dimensions**. In Proceedings of the IEEE Information Visualization Symposium, Late Breaking Hot Topics. **Anais...2000**

KEIM, D. A. Visual Techniques for Exploring Databases. **ACM KDD**, 1997.

KEIM, D. A. Information visualization and visual data mining. **IEEE Transactions on Visualization and Computer Graphics**, v. 8, n. 1, p. 1–8, 2002.

KEIM, D. A. Information Visualization. In: **Exploring Geovisualization**. [s.l.] Elsevier, 2005. p. 21–52.

KEIM, D. A.; SIPS, M.; ANKERST, M. Visual Data-Mining Techniques. In: **Visualization Handbook**. [s.l.] Elsevier, 2005. p. 831–843.

KHALID, N. E. A. et al. Multidimensional Data Medical Dataset Using Interactive Visualization Star Coordinate Technique. **Procedia Computer Science**, v. 42, n. C, p. 247–254, 2014.

KHALIFA, N. H. et al. **Interaction Visualisation of Complex Genomic Data with Game Engines**. 2017 21st International Conference Information Visualisation (IV). **Anais...IEEE**, jul. 2017Disponível em: <<http://ieeexplore.ieee.org/document/8107959/>>

KRUSKAL, J. B. Multidimensional scaling by optimizing goodness of fit to a nonmetric hypothesis. **Psychometrika**, v. 29, n. 1, p. 1–27, mar. 1964.

KUMAR, R. S.; SENTHILMURUGAN, M. Content-Based Image Retrieval System in Medical Applications. **International Journal of Engineering Research &**

Technology (IJERT), v. 2, n. 3, 2013.

KUNTTU, I. et al. Multiscale Fourier descriptors for defect image retrieval. **Pattern Recognition Letters**, v. 27, n. 2, p. 123–132, jan. 2006.

LONCARIC, S. A survey of shape analysis techniques. **Pattern Recognition**, v. 31, n. 8, p. 983–1001, ago. 1998.

LUX, M. et al. **LIRE**. Proceedings of the 7th International Conference on Multimedia Systems - MMSys '16. **Anais...**New York, New York, USA: ACM Press, 2016Disponível em: <<http://dl.acm.org/citation.cfm?doid=2910017.2910630>>

MAATEN, L. VAN DER; HINTON, G. Visualizing Data using t-SNE Laurens. **Annals of Operations Research**, p. 187–202, 20 ago. 2008.

MÜLLER, H. et al. A review of content-based image retrieval systems in medical applications—clinical benefits and future directions. **International Journal of Medical Informatics**, v. 73, n. 1, p. 1–23, fev. 2004.

OLIVEIRA, M. C. F. DE; LEVKOWITZ, H. From visual data exploration to visual data mining: A survey. **IEEE Transactions on Visualization and Computer Graphics**, v. 9, n. 3, p. 378–394, jul. 2003.

PAULOVICH, F. V. et al. Least Square Projection: A Fast High-Precision Multidimensional Projection Technique and Its Application to Document Mapping. **IEEE Transactions on Visualization and Computer Graphics**, v. 14, n. 3, p. 564–575, maio 2008.

PAULOVICH, F. V. et al. A Fast Projection Technique and its Applications to Visualization of Large Data Sets. p. 1–23, 2010.

PAULOVICH, F. V. et al. Piece wise Laplacian-based Projection for Interactive Data Exploration and Organization. **Proceedings of the 13th Eurographics/IEEE – VGTC Conference on Visualization (EuroVis'11)**, v. 30, n. 3, p. 1091–1100, jun. 2011.

PETRAKIS, E. G. M.; FALOUTSOS, C. Similarity searching in medical image databases. **IEEE Transactions on Knowledge and Data Engineering**, v. 9, n. 3, p. 435–447, 1997.

RAO, R.; CARD, S. K. **The table lens**. Proceedings of the SIGCHI conference on Human factors in computing systems celebrating interdependence - CHI '94. **Anais...**New York, New York, USA: ACM Press, 1994

RODRIGUES JR., J. F. et al. **Combining Visual Analytics and Content Based Data Retrieval Technology for Efficient Data Analysis**. 2010 14th International Conference Information Visualisation. **Anais...**IEEE, jul. 2010

RODRIGUES JR., J. F.; ROMANI, L. A. S.; CIFERRI, R. R. **MetricSPlat - A platform for quick development , testing and visualization of content-based retrieval techniques**. Simpósio Brasileiro de Bancos de Dados - SBB2009. **Anais...**2009

RODRIGUES JR., J. F.; TRAINA, A. J. M.; TRAINA JR., C. **Enhanced visual evaluation of feature extractors for image mining**. The 3rd ACS/IEEE International Conference on Computer Systems and Applications, 2005. **Anais...**IEEE, 2005

SHEREENA, V. B.; DAVID, J. M. **Content Based Image Retrieval: A Review**. Computer Science & Information Technology (CS & IT). **Anais...**Academy & Industry Research Collaboration Center (AIRCC), 13 set. 2014

SHIVAMURTHY, R. C.; MANJUNATHA, M. B.; PRADEEP KUMAR, B. P. A COMPARATIVE STUDY ON PROCEDURES ON CONTENT-BASED IMAGE RETRIEVAL IN MEDICAL IMAGING. **International Journal of Computer Engineering and Technology**, v. 5, n. 10, p. 64–73, 2015.

SHNEIDERMAN, B. Tree visualization with tree-maps: 2-d space-filling approach. **ACM Transactions on Graphics**, v. 11, n. 1, p. 92–99, 2 jan. 1992.

SHNEIDERMAN, B. **The eyes have it: a task by data type taxonomy for information visualizations**. Proceedings 1996 IEEE Symposium on Visual Languages. **Anais...**IEEE Comput. Soc. Press, 1996

SHNEIDERMAN, B.; PLAISANT, C.; HESSE, B. W. Improving Healthcare with Interactive Visualization. **Computer**, v. 46, n. 5, p. 58–66, maio 2013.

SINGHAI, N.; SHANDILYA, S. K. A Survey On: “Content Based Image Retrieval Systems”. **International Journal of Computer Applications**, v. 4, n. 2, p. 22–26, 10 jul. 2010.

SMEULDERS, A. W. M. et al. Content-based image retrieval at the end of the early

years. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 22, n. 12, p. 1349–1380, 2000.

SORZANO, C. O. S.; VARGAS, J.; MONTANO, A. P. A survey of dimensionality reduction techniques. **arXiv preprint arXiv:1403.2877**, p. 1–35, 12 mar. 2014.

SOUSA, I. C. O. V. DE; BUENO, R. **Análise da Evolução Temporal de Dados Complexos- SBB**D, 2014.

SWAIN, M. J.; BALLARD, D. H. Color indexing. **International Journal of Computer Vision**, v. 7, n. 1, p. 11–32, nov. 1991.

TORRES, R. D. S.; FALCÃO, A. X. Content-Based Image Retrieval: Theory and Applications. **Revista de Informática Teórica e Aplicada RITA**, v. 13, n. 2, p. 161–185, 2006.

TRAINA, A. J. M.; TRAINA JR., C.; BOTELHO, E. Visualização de Dados em Sistemas de Bases de Dados Relacionais. **Sbb**d, v. d, 2001.

TRAINA JR., C. et al. Slim-Trees: High Performance Metric Trees Minimizing Overlap between Nodes. **7th International Conference on Extending Database Technology**, p. 51–65, 2000.

TRAINA JR., C. et al. **How to improve the pruning ability of dynamic metric access methods**. Proceedings of the eleventh international conference on Information and knowledge management - CIKM '02. **Anais...**New York, New York, USA: ACM Press, 2002

VARGHESE, N. A Survey Of Dimensionality Reduction And Classification Methods. **International Journal of Computer Science & Engineering Survey**, v. 3, n. 3, p. 45–54, 30 jun. 2012.

WAGNER, M. et al. **Native Cross-Platform Visualization: A Proof of Concept Based on the Unity3D Game Engine**. 2016 20th International Conference Information Visualisation (IV). **Anais...IEEE**, jul. 2016Disponível em: <<http://ieeexplore.ieee.org/document/7557901/>>

WANG, H. H.; MOHAMAD, D.; ISMAIL, N. A. Approaches, Challenges and Future Direction of Image Retrieval. **Journal of Computing**, v. 2, n. 6, p. 193–199, 2010.

WARD, M. O. **XmdvTool: integrating multiple methods for visualizing multivariate data**. Proceedings Visualization '94. **Anais...**IEEE Comput. Soc. Press, 1994

WESTMAN, S.; LUSTILA, A.; OITTINEN, P. **Search strategies in multimodal image retrieval**. Proceedings of the second international symposium on Information interaction in context - IliX '08. **Anais...**New York, New York, USA: ACM Press, 2008Disponível em: <<http://portal.acm.org/citation.cfm?doid=1414694.1414700>>

WILSON, D. R.; MARTINEZ, T. R. Improved heterogeneous distance functions. **Journal of Artificial Intelligence Research**, v. 6, p. 1–34, 1997.

YADAV, R. B. et al. Vehicular shape-based objects classification using Fourier descriptor technique. **Journal of Scientific & Industrial Research**, v. 68, n. 68, p. 484–495, 2009.

YANG, J. et al. Two-dimensional pca: a new approach to appearance-based face representation and recognition. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 26, n. 1, p. 131–137, jan. 2004.

YANG, Z.; KAMATA, S. NIR : Content Based Image Retrieval on Cloud Computing. **Intelligent Computing and Intelligent Systems,IEEE International Conference**, v. 3, n. 2009, p. 556–559, 2009.

ZHANG, D.; LU, G. **A Comparative Study on Shape Retrieval Using Fourier Descriptors with Different Shape Signatures**. Proc. International Conference on Intelligent Multimedia and Distance Education (ICIMADE01). **Anais...**2001

ZHANG, D.; LU, G. Review of shape representation and description techniques. **Pattern Recognition**, v. 37, n. 1, p. 1–19, jan. 2004.

ZHANG, E.; STASKO, J. **Focus+ Context Display and Navigation Techniques for Enhancing Radial, Space-Filling Hierarchy Visualizations**. Proceedings of the IEEE Symposium on Information Visualization 2000. **Anais...**2000

ZHANG, J. et al. DIRS: Distributed image retrieval system based on MapReduce. **5th International Conference on Pervasive Computing and Applications**, p. 93–98, 2010.